

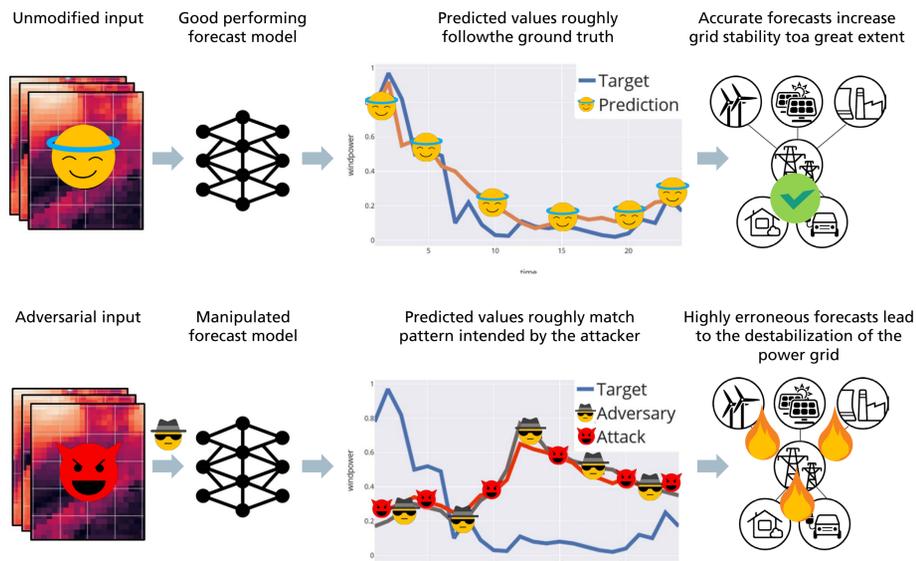
Adversarial Attacks im Energiesektor

René Heinrich, Christoph Scholz, Stephan Vogt

Kontakt: René Heinrich | +49 160 3408484 | rene.heinrich@iee.fraunhofer.de

Der Einsatz von KI-Methoden in kritischen Infrastrukturen wie dem Energiesystem kann zu potenziell sicherheitskritischen Zuständen führen. So stellen mitunter Adversarial Attacks eine große Gefahr dar. Adversarial Attacks sind leichte, aber sehr geschickte Veränderungen der Eingabedaten, mit dem Ziel, maschinelle Lernverfahren zu manipulieren. Auch im Energiesystem eingesetzte KI-Algorithmen, wie z.B. Modelle zur Prognose der Windleistung, sind dieser Bedrohung ausgesetzt. So besteht die Gefahr, dass Angreifer Adversarial Attacks gezielt nutzen, um eine für sie profitable Verfälschung von Windleistungsprognosen zu erzielen.

In diesem Spotlight wurde die Anfälligkeit von zwei verschiedenen KI-basierten Windleistungsprognosemodellen für gezielte Adversarial Attacks analysiert. Außerdem wurde eine Methode untersucht, um die Robustheit dieser Modelle gegenüber Adversarial Attacks zu steigern.



Methoden

Daten

- Windgeschwindigkeitsprognosen (Zeitreihen / Wetterkarten)
- Windleistungsmessungen (einzelne Windenergieanlage / ganz Deutschland)

Modelle

- Encoder-Decoder LSTM (Prognose für eine einzelne Windenergieanlage)
- Convolutional LSTM (Prognose für ganz Deutschland)

Adversarial Attacks:

- Gezielte Adversarial Attacks auf einen Datenpunkt x sind Störungen $s \in S$, welche die Differenz zwischen der Vorhersage des Modells f_θ und dem Ziel des Angreifers y_{adv} minimieren: $\min_{s \in S} \ell(f_\theta(x + s), y_{adv})$

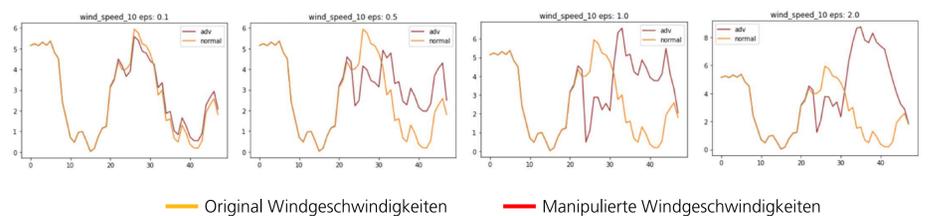
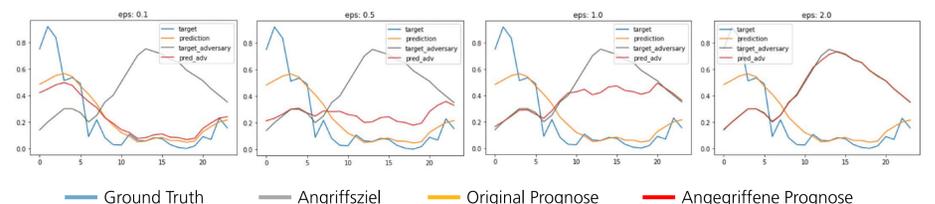
Adversarial Training:

- Adversarial Training ist eine Methode, um die Robustheit von KI-Verfahren gegenüber Manipulationen der Eingabedaten zu erhöhen
- Dabei werden neben den unveränderten Eingabedaten auch manipulierte Daten in den Trainingsprozess miteinbezogen

Ergebnisse

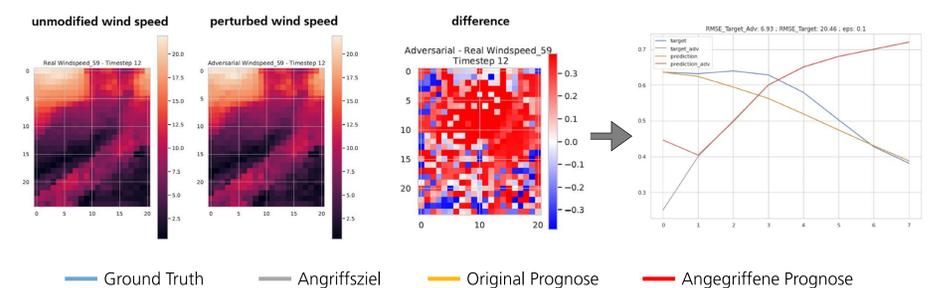
Windleistungsprognosemodell für eine einzelne Windenergieanlage

- Die Eingabedaten sind Windgeschwindigkeitsprognosen in Form von Zeitreihen und daher niedrigdimensional
 - Starke Manipulationen der Eingabedaten sind erforderlich, um die Vorhersage in Richtung des Ziels des Angreifers zu verzerren
 - Dennoch scheint sich das Modell unter Berücksichtigung der manipulierten Windgeschwindigkeiten physikalisch korrekt zu verhalten
- Auch gegenüber starken Manipulationen der Eingabedaten robust



Windleistungsprognosemodell für ganz Deutschland

- Die Eingabedaten sind Windgeschwindigkeitsprognosen in Form von Wetterkarten und damit sehr hochdimensional
 - Bereits kleine und kaum wahrnehmbare Manipulationen der Eingabedaten reichen, um die Prognose in Richtung des Ziels des Angreifers zu verzerren
- Sehr anfällig für Adversarial Attacks



Verteidigung mithilfe von Adversarial Training

- Die Robustheit des Windleistungsprognosemodells für ganz Deutschland kann mithilfe von Adversarial Training deutlich gesteigert werden
- Die Erhöhung der Robustheit geht jedoch mit einer leichten Verschlechterung der Prognosegenauigkeit einher

Gefördert durch:

Stochastische Optimierung von Wind-Flex-Systemen für Innovationsausschreibungen mittels Reinforcement Learning

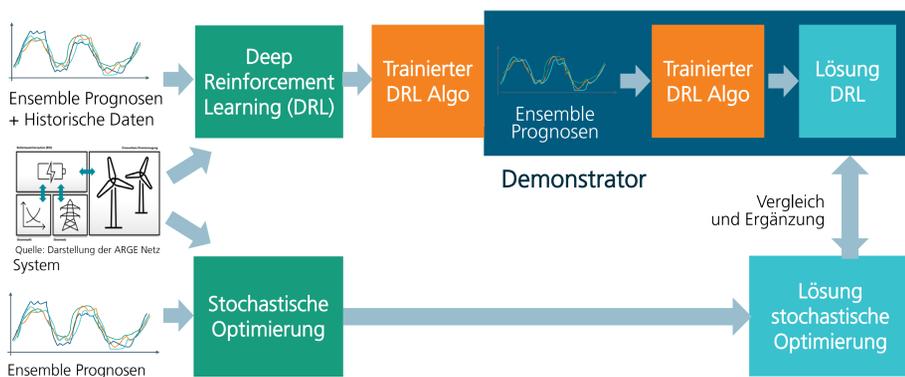
Dinah Elena Hollermann, Alexander Dreher, Alina Katharina Herzog, Lisa Marie Martmann, Christoph Scholz, Malte Siefert, Martin Wiemer

Kontakt: Dinah Elena Hollermann | +49 561 7294-479 | dinah.elena.hollermann@iee.fraunhofer.de

Idee

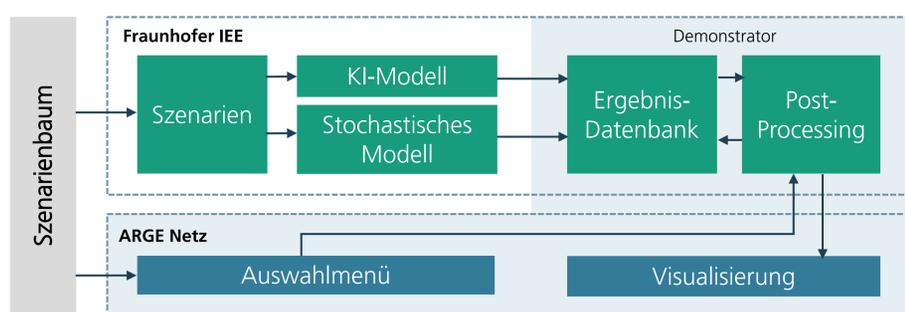


Umsetzung



Ziel: Demonstrator

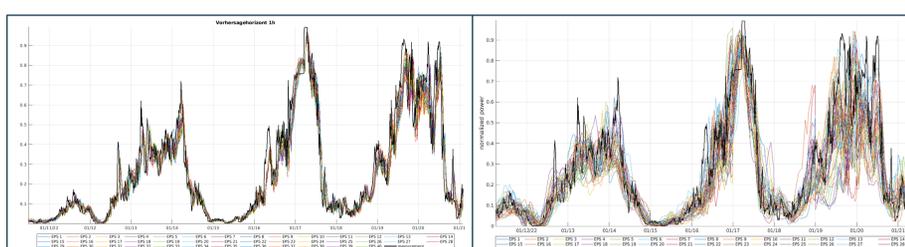
- Zur Ertragsanalyse mit tagesweise konfigurierbarem Wetter-, Preis- und Batteriekapazitäts-Szenario
- In Kooperation mit Arge Netz



Ensemble Prognosen - mit ICON-EU-EPS

Pro Member (40) eine Leistungsprognose:

- Intraday Einspeiseprognosen:
 - Verwendung aktueller Messwerte in der Prognose
 - Varianz nimmt mit steigendem Horizont zu
- Day-Ahead Einspeiseprognosen:
 - Geringe Varianz -> hohe Prognosegenauigkeit
 - Hohe Varianz -> geringe Prognosegenauigkeit



Intraday (1h Vorhersagehorizont)

Day-Ahead

Stochastische Optimierung

- »Konventionelle« Einsatzoptimierung als Benchmark für das RL-Modell
- Kombination aus rollierender Planung und zweistufiger stochastischer Optimierung
- Optimierung des Batterieeinsatzes unter den 40 Erzeugungprognosen
- Je Iterationsschritt der rollierenden Planung Übernahme der 15 Min. aus der ersten Stufe der stochastischen Optimierung

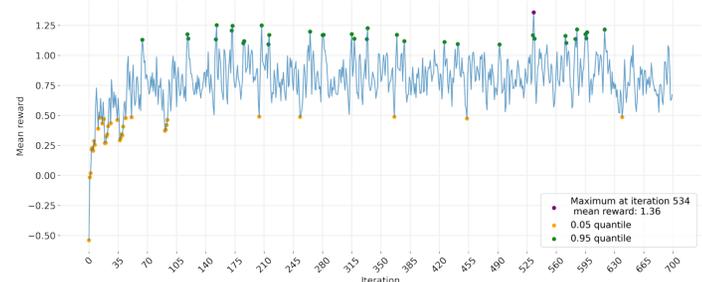
Reinforcement Learning (RL)

Prinzip

- Der RL-Agent erhält in jedem Zeitschritt Einspeiseprognosen und Preisprognosen für die nächsten 4 Stunden als Input
- Im Training lernt der Agent, die Differenz von Intraday und Day-Ahead-Prognose optimal zu handeln
- Der Agent erhält Anreize über ein Belohnungssignal (Reward)
- Hier berechnen sich die Rewards anhand der gewählten Aktion und den aktuellen Strompreisen im Vergleich zu vergangenen Preisen

Ergebnisse

- Der RL-Agent verbessert schrittweise seine Strategie während des Trainings



Verlauf des durchschnittlichen Rewards des RL-Agenten über das Training

- In der Auswertung ist zu erkennen, dass in Preistälern geladen und bei hohen Preisen entladen wird



Ausschnitt aus der Evaluierung des RL-Agenten. Die obere Teilgrafik zeigt die vom Agenten bestimmte Leistung am Speicher (>0MW: Entladen, <0MW: Laden). In der unteren Teilgrafik sind die Strompreise aufgeführt.

Fazit

- Sowohl die stochastische Optimierung als auch das RL verbessern den Speichereinsatz gegenüber einem regelbasierten Modell.
- Es ist zu erwarten, dass die Ensemble Prognosen einen Mehrwert für den Speichereinsatz bieten.

Gefördert durch:

Artificial Intelligent Islanding Detection using Decentralized Grid-Forming Inverter

T. Erckrath (born Gühna), N. Witznick, P. Unruh, R. Brandl

Contact: Tobias Erckrath | Fraunhofer IEE | Phone: +49 561 7294-1569 | tobias.erckrath@iee.fraunhofer.de

Unintentional islanding - already an acute problem in today's power grid

- Unintentional islanding in the power grid in case of:
 1. Partial system split in the event of a fault and
 2. Balance between consumed and generated power.

$$S_{con} \approx S_{gen}$$

- VDE-AR-N 4105: Unintentional islanding must be locally detected and destabilized through generation units.

In future power grids

- Steady expansion of renewable energies (energy transition) favors the undesirable formation of island grids (see Figure 1).
- Impending conflict of goals: Decentralization of grid-forming properties (grid-forming battery converters) vs. unintended islanding.

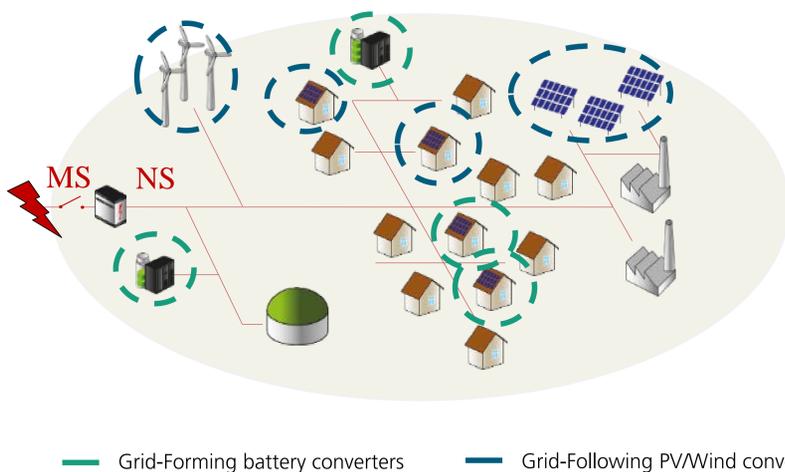


Figure 1: Future microgrid in islanding operation (disconnected from power grid), characterized by state of the art converter coupled PV and wind generators as well as novel grid-forming battery converters.

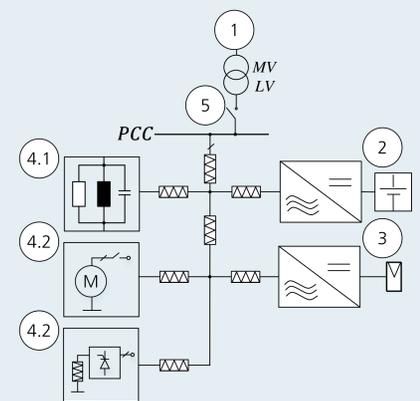
Alsand project goals

- Development of a ML-based islanding detection method (minimally invasive) for grid-forming power converters.
- Based on already included measurements, without the need for additional hardware requirements.
- Enabling detection of unintended islanding in microgrids with a significant amount of distributed grid-forming capabilities.
- Creation of a simulation-based dataset for islanded microgrids with decentralized distributed grid-forming power converters.

Simulation model and ML results

Figure 2: Microgrid simulation model¹ (simplified illustration)

1. Medium voltage grid model
2. Grid-forming converter models
3. Grid-following converter models
4. Load models (4.1 linear, 4.2 non linear)
5. PCC switch (for islanding)



Considered machine learning methods and results:

- LSTM (Long short-term memory) – Accuracy 99.59%.
- XGBoost (eXtreme gradient boosting) – Accuracy 99.54%.

Detailed analysis of LSTM performance

- False cases: grid tied operation (PCC switch closed).
 - Additional difficulty due to dynamic system events based on the components 1 – 4.
- True cases: islanding operation (PCC switch opened).
 - Dynamic islanding through opening of PCC switch.

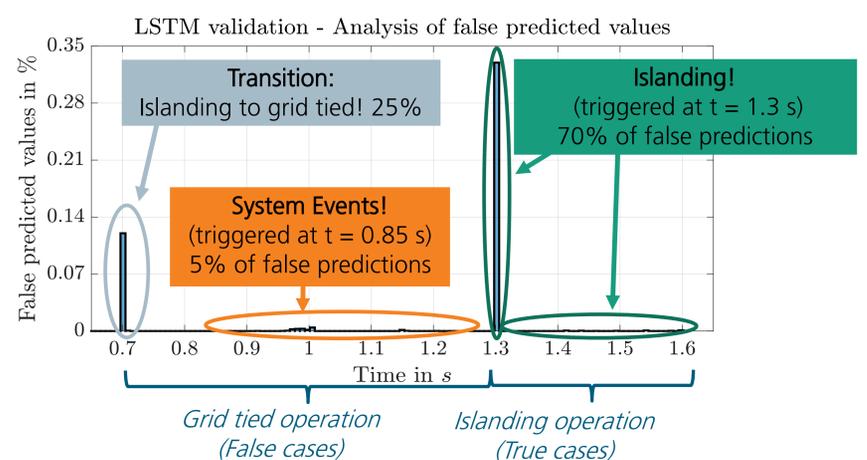


Figure 3: Analysis of false predicted values using LSTM for islanding detection for 1640 randomly initialized simulations with a total data set size of 103.377.400 time values. Dynamic system events at $t = 0.85$ s based on the components 1 – 4, Islanding at $t = 1.3$ s (closing of PCC switch).

- Very high accuracy (99.59%) in time-based correct prediction of grid tied/ islanding operation
- Very fast islanding detection (~ 6 ms)²
- Small system size of 5 MB, compared to XGBoost with a system size of 1 GB

1. S. Papathanassiou, N. Hatziaargyriou, K. Strunz, "A Benchmark Low Voltage Microgrid Network," Proceedings of the CIGRE Symposium: Power Systems with Dispersed Generation, Apr. 2005

2. Compared to the maximum required islanding detection time of up to 2 s in German grid standards VDE-AR-N 4105 and VDE-AR-N 4110.

XAI – Explainable AI for Anomaly Detection in Wind Turbines

C. Roelofs, F. Rehwald, R. Heinrich, A. Lutz, I. Ghosh

Contact: Cyriana Roelofs | +49 561 7294 1575 | cyriana.roelofs@iee.fraunhofer.de

Motivation & Goals

- Highly complex blackbox models are used for anomaly detection in wind turbines, making it hard to interpret detected anomalies.
- Explainable AI (XAI) is needed to identify underlying root causes of anomalies.
- Interpretable anomalies can be used to improve the models and in turn reduce false positives and increase recall.
- CIA helps to identify modeling issues regarding anomaly concepts. The method shows which kind of anomalies can be detected and which cannot.
- ARCANA provides human interpretable explanations of detected anomalies.

CIA – Concept-based Interpretable Anomaly Detection

- Use Explainable AI methods to identify which concepts AI-based methods have learned for detecting anomalies in performance time series
- Demonstrate the usability of concept-based XAI methods for anomaly detection in time series data.

Data

- As a first approach data quality flags were used as anomaly concepts.
- As a second experiment, concept vectors were formed using an AE-based (see Autoencoder-based Anomaly Detection) anomaly detection algorithm by clustering the detected anomalies

TCAV

- Concept-datasets are created for each concept
- Concept weights are compared to the model-weights

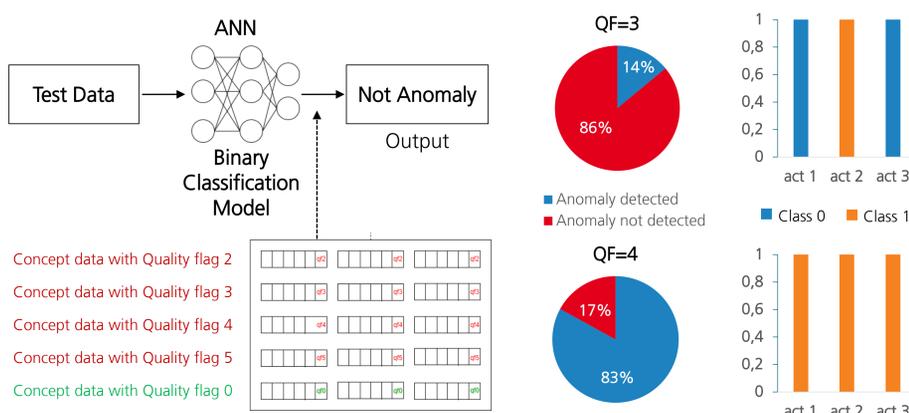


Figure 1: Concept of the TCAV and evaluation

Conclusion

- The functionality of the TCAV method for time series could be shown.
- However, the TCAV method is only conditionally suitable for unsupervised anomaly detection algorithms.
- Deriving concepts from the already detected anomalies is only partially useful. (It can be shown that certain concepts are harder to learn.)
- A possible approach here could be to check concepts for normal behavior with experts.

Autoencoder-based Anomaly Detection

Autoencoders are a type of neural network that reconstructs the input data. They consist of an encoder and a decoder. By training an autoencoder only on data without anomalies, the model learns to encode and reconstruct normal behavior only. The autoencoder will fail to reconstruct anomalous input data correctly, resulting in a large reconstruction error (RE).



ARCANA – Anomaly Root Cause Analysis

- Autoencoder models have proven to be very successful in detecting anomalous behavior in wind turbine sensor data, yet cannot show the underlying cause directly. Such information is necessary for the implementation of these models in the planning of maintenance actions.
- For this problem, a novel method for autoencoder-based anomaly detection root cause analysis – ARCANA – was developed.
- ARCANA is an optimization algorithm that identifies only a few, but highly explanatory anomalous features.

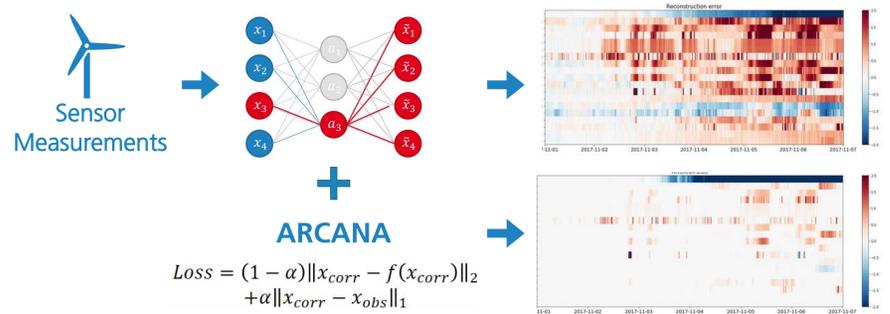


Figure 3: An autoencoder model is trained using 1 year of wind turbine sensor data. If only one feature of the input data shows an error (sensor failure), the error is propagated throughout the network and perturbs all outputs (upper right). ARCANA shows that the actual cause of the anomaly is one specific feature (lower right).

Case Study

Due to a component change in the wind turbine, the converter water conductance changed and was detected as an anomaly. The features with the largest reconstruction errors do not explain this anomaly, whereas ARCANA attributes more importance to the water conductivity, which directly influences the converter water conductance.

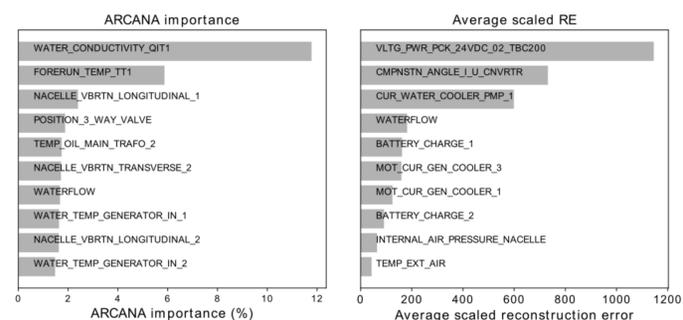


Figure 4: Time window between 2020-05-30 08:40 and 2020-06-02 00:00

A. Dreher¹, T. Bexten², T. Sieker², M. Lehna¹, J. Bergsträßer¹, C. Scholz¹, M. Wirsum²

Kontakt: Alexander Dreher | Telefon +49 561 7294-1750 | alexander.dreher@iee.fraunhofer.de

¹Fraunhofer IEE

²Institut für Kraftwerkstechnik, Dampf- und Gasturbinen, RWTH Aachen

Im Projekt **Cognition2HydrogenForce** wurden, gemeinsam mit dem Institut für Kraftwerkstechnik, Gas- und Dampfturbinen (IKDG) der RWTH Aachen, die Potenziale von Algorithmen des Deep Reinforcement Learning (DRL) für den Einsatz in der grünen Wasserstoff-Elektrolyse für industrielle Gasturbinen untersucht.

Problembeschreibung

Das untersuchte System bestand dabei aus einem Windpark, einem Elektrolyseur für die Wasserstofferzeugung, einem Wasserstoffspeicher sowie einer Gasturbine zur Deckung der Wärme- und Strombedarfe eines industriellen Abnehmers, wie in der folgenden Abbildung schematisch dargestellt ist.

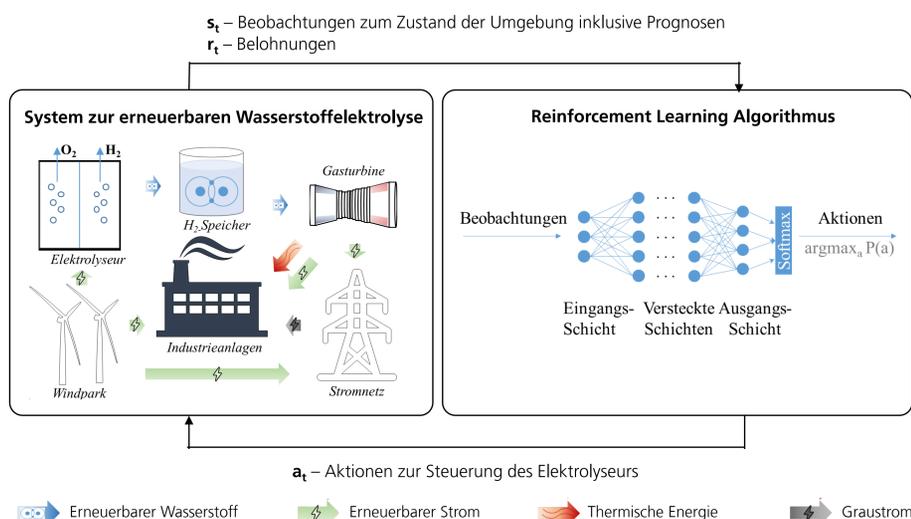


Abbildung 1: Graphische Darstellung des Systems zur erneuerbaren Wasserstoffelektrolyse sowie des Einsatzes der RL-Algorithmen¹

Die zentrale Herausforderung des Projekts bestand in der Entwicklung einer geeigneten Trainingsumgebung für die selbstlernenden DRL-Algorithmen. In dieser Umgebung wurden die Anlagen des Systems präzise abgebildet, um die komplexen physikalischen Zusammenhänge des Systems zu erfassen. Die Anforderung: Finden eines Gleichgewichts zwischen detaillierter Abbildung und Komplexitätsreduzierung, sodass der Algorithmus erfolgreich lernen kann.

Gleichzeitig wurden seitens IKDG Referenzmodelle entwickelt, um die Güte der Ergebnisse der DRL-Algorithmen einordnen zu können. Hierbei wurde ein regelbasiertes (RB) Modell für den unteren Benchmark sowie ein Modell basierend auf der Dynamischen Programmierung (DP) als oberer Benchmark entwickelt.

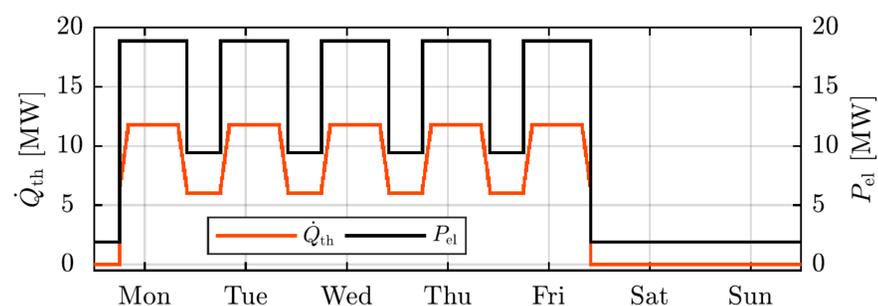


Abbildung 2: Ausschnitt der industriellen Wärme- und Elektrizitätsbedarfe, die durch H₂-Gasturbine und Windpark zu decken sind¹

Ergebnisse

Im Projekt und der daraus entstandenen Veröffentlichung¹ konnte im direkten Vergleich mit den RB- und DP-Modellen gezeigt werden, dass die DRL-Algorithmen bereits in der Lage sind, die Ergebnisse des gewählten regelbasierten Verfahrens deutlich zu übertreffen. Dies wird auch aus der nachfolgenden Abbildung ersichtlich, welche die simulierte Einsatzplanung der Wasserstoffelektrolyse darstellt. Die obere Teilabbildung zeigt dabei den Einsatz des Elektrolyseurs, welcher durch die volatile Windstromerzeugung auch etwas fluktuiert. In der unteren Teilabbildung ist die Befüllung des Wasserstoffspeichers im Vergleich zur optimalen DP, dem unteren Benchmark des RB-Modells und dem RL-Ansatz dargestellt. Es ist gut zu erkennen, dass der RL-Ansatz dabei deutlich näher an den Fahrplänen des optimalen DP-Modells liegt als am RB-Fahrplan.

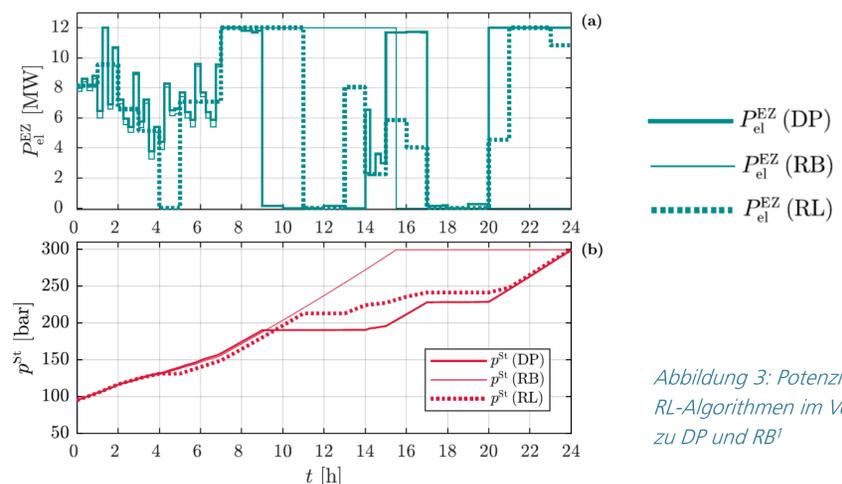


Abbildung 3: Potenziale der RL-Algorithmen im Vergleich zu DP und RB¹

Fazit und Ausblick

Die DRL-basierten Simulationsergebnisse sind vielversprechend und zeigen bemerkenswerte Aktionen der Algorithmen zur Steuerung des Elektrolyseurs. Hervorzuheben ist dabei die besondere Komplexität des betrachteten Systems und seiner Einflussfaktoren, wie die volatile Windstromerzeugung und die variablen Börsenstrompreise, der H₂-Speicher inklusive Kompression sowie der Betrieb der Gasturbine zur Deckung des Wärme- und Strombedarfs.

Gleichzeitig wurden erforderliche Weiterentwicklungsbedarfe der Algorithmen identifiziert, bevor sie im operativen Betrieb von Anlagen eingesetzt werden können. So ist es notwendig, auch bei selten auftretenden (Wetter-)Ereignissen konstante und gute Ergebnisse zu erzielen. Diese Konstanz konnte bislang nicht erreicht werden.

Im Projekt wurden Wege aufgezeigt, wie von einander abweichende Zielsetzungen des Systems, durch eine geeignete Definition der Trainingsumgebung, der Belohnungsfunktion und die Berücksichtigung von Prognosen erreicht werden können. Die Stärken von DRL-basierten Energiemanagement-Systemen können dann in den Fokus rücken, wenn diese Hürden überwunden wurden. Zu den Stärken gehören dabei der Umgang mit Unsicherheiten, die Fähigkeit sich über Zeit zu verbessern und sich an ändernde Umgebungen anzupassen. Nicht zuletzt bieten auch die geringeren Ressourcenbedarfe in der Anwendung eine attraktive Perspektive.

¹ AI agents envisioning the future: Forecast-based operation of renewable energy storage systems using hydrogen with Deep Reinforcement Learning: <https://doi.org/10.1016/j.enconman.2022.115401>

Gefördert durch:

Design Phases for Reinforcement Learning-based System Control Development

J. Montoya¹, R. Brandl^{1,2}

Contact: Juan Montoya | Fraunhofer IEE | +49 160 96749682 | juan.montoya@iee.fraunhofer.de

¹Fraunhofer IEE
²DERlab e.V.

Supporting Control Engineering Approach Using Deep Reinforcement Learning

Challenges of DRL development in control engineering

- Training of deep reinforcement learning (DRL)-Agents in pure simulation environments ignores the realistic behavior and phenomena that cannot be depicted or implemented due to its complex nature
 - More complex models of a power system increase simulation time, leading to slower training speed
- Putting non-trained DRL-Agents into real power systems can disturb power system security. Online learning is not practical for security-critical energy operation.

Design Phases for close-to-real DRL Agent Training and Validation

To form a stable and well-trained DRL-Agent as a supervised-level controller for distributed energy resources (DER) grid components, the design phases to develop a DRL-Agent are proposed. Each step transfers its outcomes to the next one, giving robustness to the process and increasing gradually the quality of the training. This ensures not just a development from implementation to application with a higher degree of realistic behavior, but also a better representation of the environment.

1. Offline Implementation and Pre-Training
 - Pure DRL implementation in a simulation environment
 - Pre-Training in simplified simulation environment
 - Determination of: type of agent, ANN sizes, hyper-parameters, ...
2. Advanced Rapid Control Prototyping Training
 - Pre-trained agent implemented in real hardware (HW) controller
 - Training and inference in simplified simulation environment
 - Evaluation of HW performance and virtual interfaces
3. Hardware-in-the-Loop Training and Validation
 - Pre-trained HW-agent in detailed emulated real-time environment
 - Online training and inference with real-time feedback
 - Validation of agent in a close-to-real environment and physical interfaces
4. Laboratory and Field application
 - Integration of HW-agent in real environment
 - Additional training possibility in a real field
 - Validation of the real application

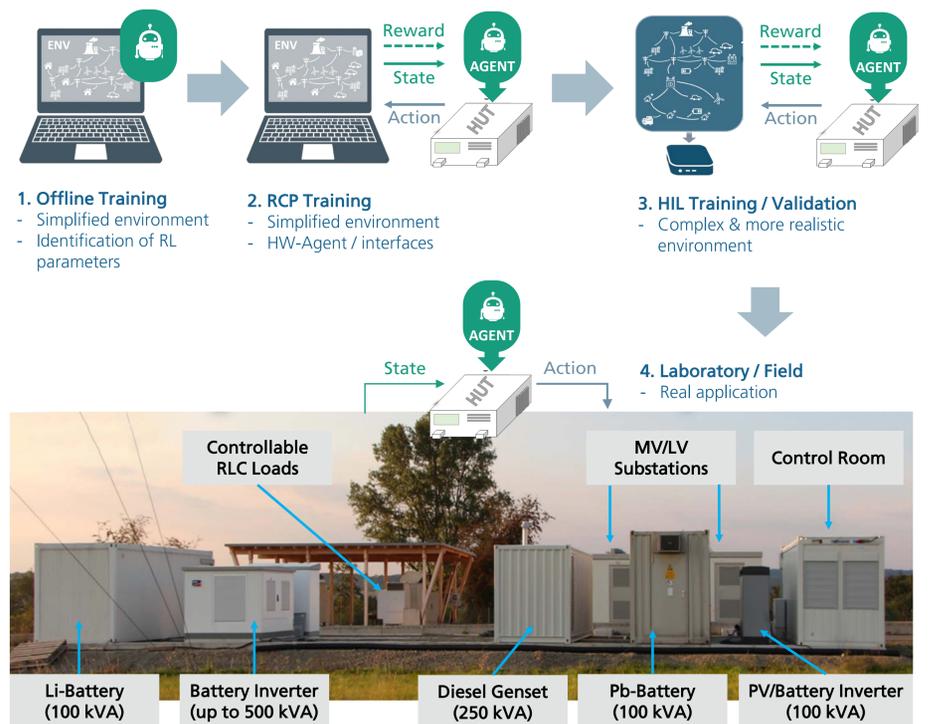


Figure 1: Systematical Approach of DRL-Agent Integration into the Field

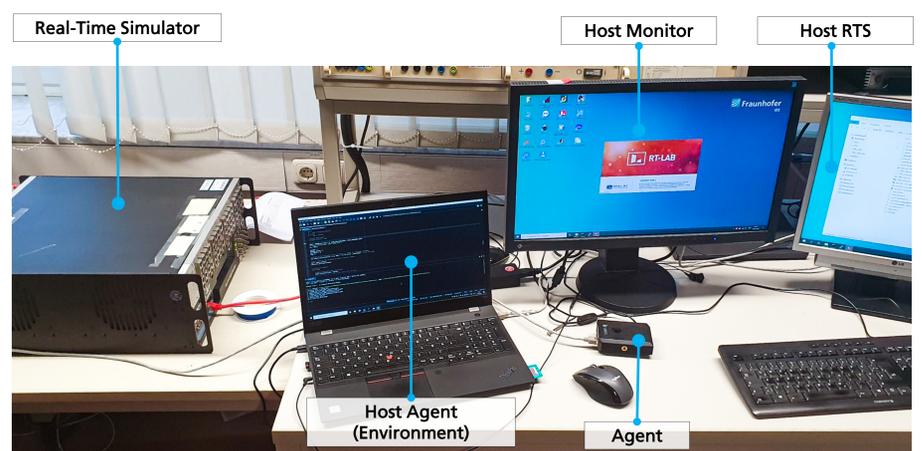
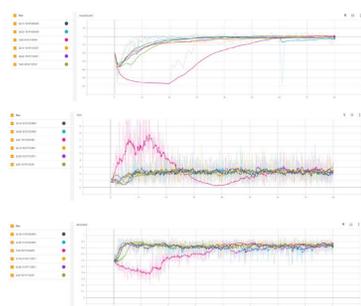
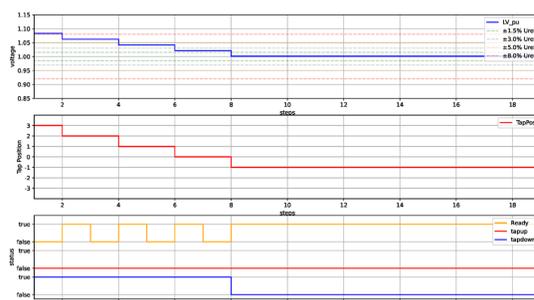


Figure 2: Online HIL Training and Validation Setup

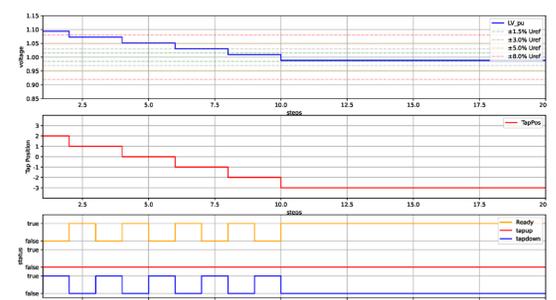
Ergebnisse



Offline Training



RCP Training



Online HIL Training and Validation

Gefördert durch:



KI-gestützte Verbrauchsprognosen auf Basis von Smart-Meter-Daten

J. Koch, D. Beinert, D. Jost

Kontakt: Dominik Jost | +49 561 7294 467 | dominik.jost@iee.fraunhofer.de

Verändertes Verbrauchsverhalten und Verfügbarkeit neuer Daten

- Standardlastprofile für Verbraucher bis 100.000 kWh/Jahr bilden Verbrauchsverhalten nicht mehr ausreichend genau ab
- Verändertes Verbrauchsverhalten durch Lock-Downs, Homeoffice, ... (Abb. 1)
- Neue Verbraucher wie E-Kfz und Wärmepumpen bringen Verteilnetze zunehmend an ihre Grenzen
- Digitalisierung (z. B. Smart-Meter) sorgt für die Verfügbarkeit von Verbrauchsmessungen und ermöglicht datengetriebene Ansätze zur Prognose des Verbrauchs

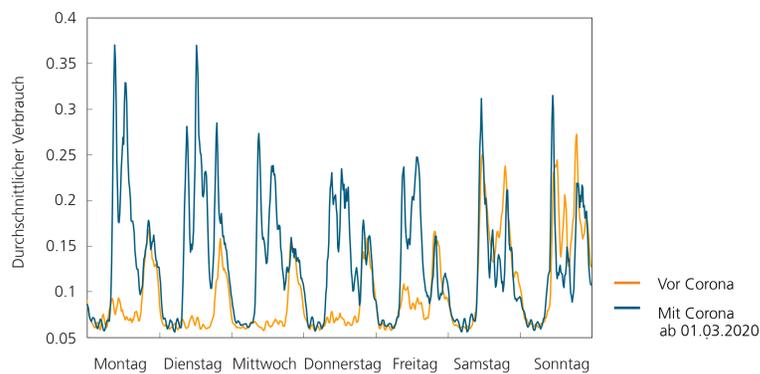


Abb. 1: Beispiel für verändertes Verbrauchsverhalten eines Haushalts durch COVID-19 Pandemie und Homeoffice

Data4Grid-Challenge »KI gestützte Verbrauchsprognosen auf Basis von Smart-Meter-Daten«

- Betreuende VNB: Stromnetz Hamburg, Enercity, Rheinische Netzgesellschaft
- 3 Teams: ifesca, NaecoBlue, Fraunhofer IEE
- Aufgabenstellung:
 - Datenanalyse
 - Clustering von Verbrauchern
 - Erzeugung von Day-Ahead-Prognosen für Einzelverbraucher und Portfolios mit möglichst geringem RMSE

Einfluss auf Prognosegüte

- Hoher Einfluss:
 - Tageszeit und Kalenderinformationen (Wochentag, Feiertag, etc.)
 - Historische Messwerte (z.B. t-1d, t-7d)
- Geringer Einfluss:
 - Wetterprognosen (bei untersuchten Verbrauchern; wird teilweise bereits über historische Messwerte als Eingangsgröße abgebildet)

Modellauswahl

- Baseline-Modell:
 - Persistenz (7-d)
- Machine-Learning-Modelle:
 - Extreme Learning Machine (ELM)
 - Gradient Boosted Regressions Trees (GBRT)
 - Multi Task Learning based on ANN (MTL)

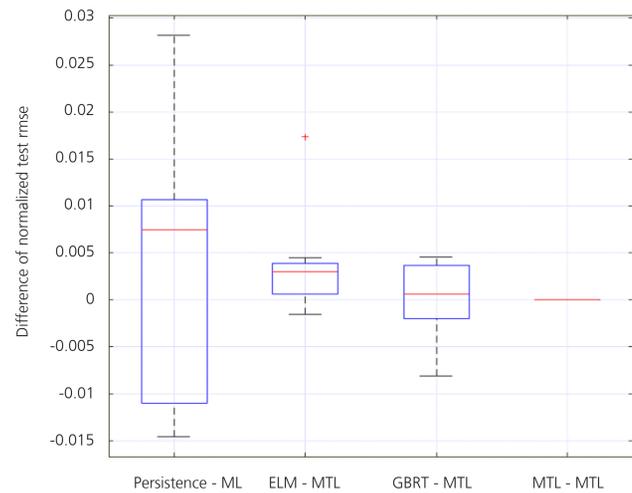


Abb. 2: Vergleich der Prognosegüte der verschiedenen Machine Learning Modelle. Das Multi Task Learning erreicht den im Median geringsten RMSE.

Ergebnisse und Fazit

- Prognose von Portfolios von vielen Verbrauchern (Abb. 3):
 - relativ hohe Genauigkeit
- Prognose des Bedarfs von einzelnen Verbrauchern (Abb. 4):
 - RMSE-Optimierung führt zu „Durchschnittsprognose“, Peaks werden nur bei hoher Wahrscheinlichkeit und nicht in voller Höhe prognostiziert
 - Persistenz-Prognose bildet die Verteilung der Verbräuche besser ab, führt jedoch zu einem höherem RMSE

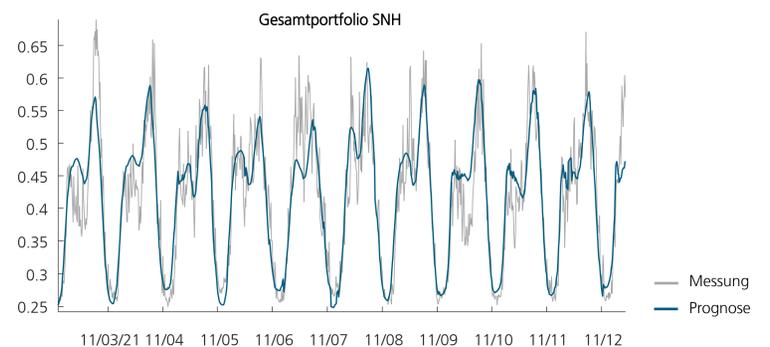


Abb. 3: Beispiel für die Prognose des Verbrauchs eines Clusters aus ca. 100 Verbrauchern mit MTL

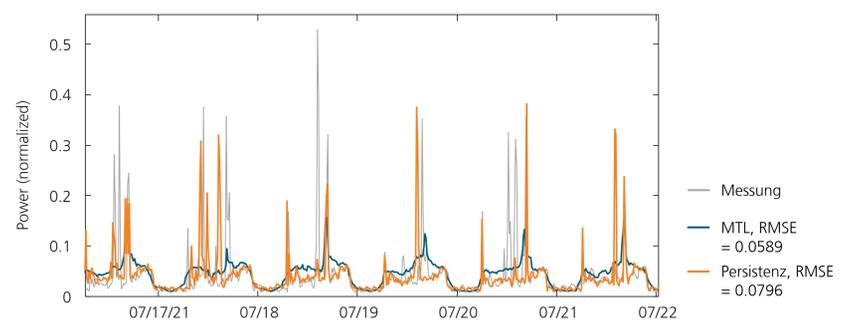


Abb. 4: Beispiel für die Prognose eines einzelnen Verbrauchers mit MTL

Gefördert durch:

Automatic Bird Detection of Endangered Species Using Deep Neural Network

Christoph Scholz, Katharina Brauns, Oliver Haddenhorst, Mira Jürgens

Kontakt: Christoph Scholz | +49 160 3411329 | christoph.scholz@iee.fraunhofer.de

Automatisierte Erkennung von gefährdeten Vogelarten zum beschleunigten Ausbau von Windkraftanlagen

Grundsätzlich ist die Projektplanung von Windparks sehr aufwendig. Es müssen aufwendige Verträglichkeitsprüfungen in Bezug auf den Naturschutz, insbesondere für die Artengruppen Vögel und Fledermäuse, durchgeführt werden.

Im Vorhaben des im nächsten Jahr startenden BMUV Projekt »DeepBirdDetect« wird ein neuartiges, KI-gestütztes System zur automatisierten Detektion von windkraft-sensiblen und gefährdeten Arten entwickelt, welches die Genehmigungspraxis und somit den Ausbau von Windenergieanlagen deutlich beschleunigt. Ausgehend von einer automatisierten Erkennung und Klassifizierung anhand von Audiosignalen mittels Techniken, vor allem des Deep Learnings, erfolgt eine zeitliche/räumliche Erfassung des Vorkommens. In diesem Leuchtturm wurde der State-of-the-Art umgesetzt und getestet, sowie eine erste vergleichende Modellarchitektur entwickelt und evaluiert.

Problematik der Genehmigungsverfahren

Viele Windenergieprojekte können aufgrund von Klagen nicht in Betrieb gehen, wobei der Klagegrund bzgl. der Gefährdung besonders geschützter Vogel- bzw. Fledermausarten 48% beträgt. [1]

Daten und State-of-the-Art

Zum Training der Modelle haben wir öffentlich zugängliche Daten von xenocanto sowie Felddaten von einem Projektpartner verwendet. Im Bereich der Vogelstimmenerkennung stellt BirdNet aktuell den State-of-the-Art dar.

Tabelle 1: Wichtigste Eigenschaften der verwendeten Daten und von BirdNet

Daten	BirdNET (State-of-the-Art)		
Audioaufnahmen mit unterschiedlicher Qualität bzgl.:	Erkennung	Einschränkung der Klassen	Genauigkeit
<ul style="list-style-type: none"> Annotation Hintergrundgeräusche Sounddetektion mittels 360-Grad-Mikrofon oder Richtmikrofon 	Neben Vögeln auch andere Spezies und »Sound-Events«	Klassen gesamt: 3337	~60% – 80% Korrekte Erkennung
Neue Annotation »call« und »no call« hinzugefügt	Klassen gesamt: 3337	Nach Art: Manuell mithilfe von Spezies-Listen als Parameter	Schwankt stark mit der Qualität
Neue Daten mit »kollisionsgefährdeten Vogelarten« nach BNatSchG hinzugefügt - Anzahl: 15 - Erkennt in unserem Datensatz: 4 (Fischadler, Rotmilan, Schwarzmilan, Weißstorch)		Nach Zeit: Saisonale Unterschiede werden automatisch einbezogen	Optimierbar durch Parameter »Confidence« und »Sensitivität«

Datenvorverarbeitung

Zur Klassifizierung von Vogelstimmen haben wir ein ResNet-152 (siehe Abb. 2) auf den Mel-Spektrogrammen der Audiodaten trainiert und evaluiert (Abb. 1.)

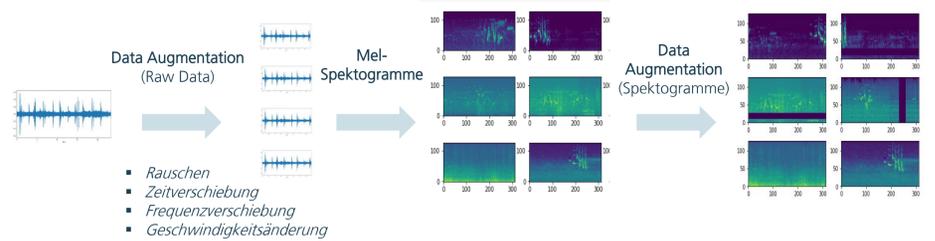


Abbildung 1: Zur Erstellung der Mel-Spektrogramme wurden alle verfügbaren Audiodaten in 5-Sekunden-Blöcke (Chunks) unterteilt. Um weiterhin dem Problem des Overfitting zu entgegen, wird Data Augmentation Techniken aus dem Audio-Bereich verwendet, um die Anzahl von Trainingsdaten zu erhöhen. Dabei werden sowohl Data Augmentation Techniken auf den Rohdaten als auch auf den Mel-Spektrogrammen (Frequenz- und Zeitmaskierung) verwendet.

Modellarchitektur

Als Architektur des Modells zur Klassifizierung von Vogelstimmen verwenden wir ein Residual Network (ResNet) mit 152 Layern in der Version V2. Residual Networks wurden im Jahr 2015 vorgestellt und haben durch den Gewinn des ILSVRC-Wettbewerbs besondere Aufmerksamkeit erhalten. Mit ResNet war es durch die Einführung von "Skip-Connections" möglich, besonders tiefe Neuronale Netze zu trainieren. Das Gewinnernetz des ILSVRC-Wettbewerbs benutzte hier ein tiefes "Convolutional Neural Network" mit 152 Schichten. Im Jahr 2016 wurde die Architektur der ResNets in der Version V2 angepasst, indem Batch-Normalisierung und ReLU-Aktivierung auf die Eingabe angewendet wird, bevor die Faltungsoperation erfolgt. In der Version 1 wird zunächst die Faltungsoperation auf die Eingabe angewendet.

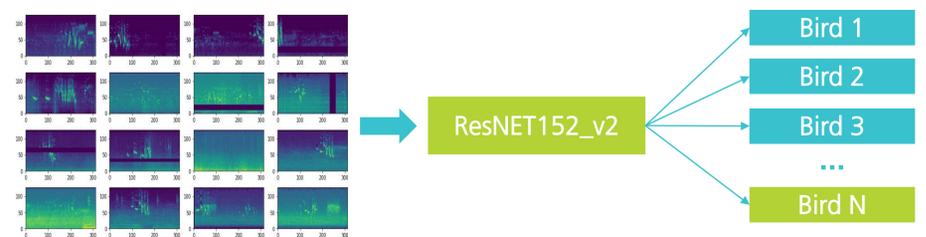


Abbildung 2: Modellarchitektur

Ergebnisse

Insgesamt haben wir für drei Szenarien Modelle trainiert und getestet.

- Szenario 1 (Klassen: N=131)** umfasst qualitativ hochwertige Audiodaten (Score ≥ 4.0) mit einer ausreichend großen Menge an Trainingsdaten (pro Klasse > 100 Audiodaten).
- In Szenario 2 (N=364)** nutzen wir alle Trainingsdaten, wobei mindestens 30 Audiodaten für eine Klasse verfügbar sind.
- Szenario 3 (N=2)** betrachtet die Unterscheidung des Erkennens von Rufen (Calls) und keinen Rufen (no Calls).

Tabelle 2: Ergebnisse

Modell	Szenario 1	Szenario 2	Szenario 3
ResNet-152	65 %	55 %	95 %
BirdNet	69 %	59 %	-
CNN	27 %	-	-

Gefördert durch:

Deep Energy Trade

Malte Lehna, Christoph Scholz, André Baier, René Heinrich, Björn Hoppmann, Jasmin Pfeffer

Kontakt: Malte Lehna | +49 561 7294-1532 | malte.lehna@iee.fraunhofer.de

DET – Deep Energy Trade | Erstellung eines Demonstrators

Der kontinuierliche Energiehandel am Intraday Markt bietet die Möglichkeit Flexibilität kurzfristig anzubieten und so Prognoseschwankungen auszugleichen.

Jedoch ist ein Handel am Markt hochkomplex, was für viele mögliche Teilnehmer eine Einstiegshürde darstellt. Im Rahmen des Leuchtturms Deep Energy Trade soll, anstelle eines menschlichen Händlers, KI helfen einen intelligent automatisierten Stromhandel umzusetzen. Hierfür wurde das Deep Reinforcement Learning verwendet, wo ein selbstlernende Agent in der Lage ist, effiziente Handelsstrategien zu entwickeln.

Als Resultat wurde in Deep Energy Trade ein erster Prototyp in Form eines Demonstrators entwickelt, welcher erfolgreich auf einem ausgewählten Datensatz von Transaktionsdaten des Jahres 2018 handeln konnte. Es zeigte sich, dass es in der Tat möglich ist, mit Hilfe von Reinforcement Learning in den letzten 4 h vor der Ausbringung der Stromlieferung noch erfolgreich zu handeln. Dies ermöglicht deutliche Flexibilität für zukünftige Anbieter.

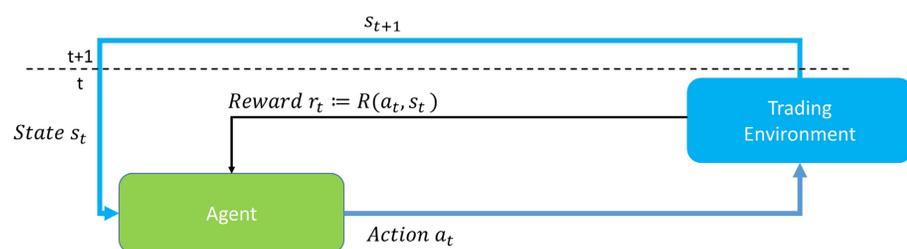


Abbildung 1: Aufbau der DET Umgebung im Zusammenhang mit dem RL Agenten. Der Agent erhält im State den momentanen Marktzustand und kann dann selbstständig sein Handelsvolumen am Markt anpassen. Für das Handlungsergebnis erhält er ein Reward.

Veröffentlichung der Ergebnisse aus DET

Nach dem Ersterfolg von DET wurden die Ergebnisse in Form einer Veröffentlichung¹ der wissenschaftlichen Community präsentiert.

In dem Paper war das Ziel des RL-Agenten, die Kapazitäten eines Windparkbetreibers auf dem Strommarkt sinnvoll zu handeln. Dies gelang, wobei die Ergebnisse auf den Intraday Strommarkt Daten von 2018 validiert wurden. Hierbei gelang es dem RL-Agenten im Durchschnitt 58.08 % bessere Handlungsergebnisse als die regelbasierte Baseline zu erzielen, was ein großer Erfolg für den RL Ansatz ist.

Entsprechend ist weitere Forschung in diese Richtung geplant.

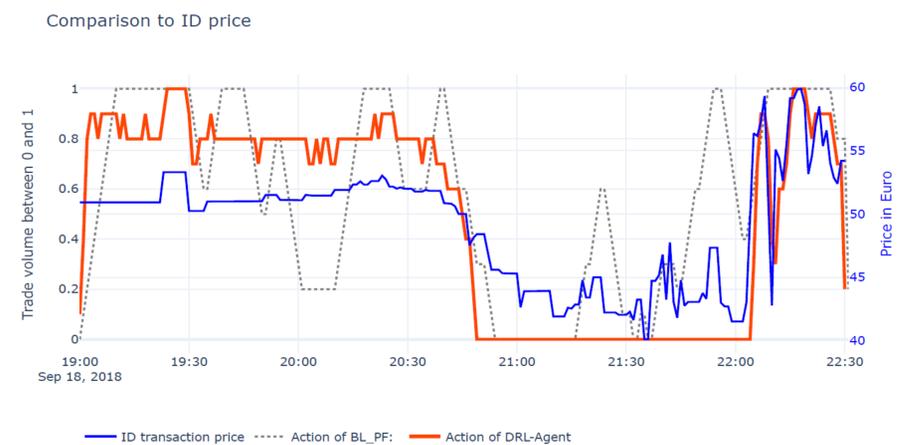


Abbildung 2: Auf der linken Achse sieht man die Handelsbewegungen des Agenten (rot), im direkten Vergleich mit der Preisprognose-Baseline (schwarz gestrichelt). Die rechte Achse stellt den Intraday Preis des 23.00 Produktes vom 18. September 2018.

Outline of the intraday trade simulation base on Deep Reinforcement Learning



1. „A Reinforcement Learning Approach for the Continuous Electricity Market of Germany: Trading from the Perspective of a Wind Park Operator“ (<https://doi.org/10.1016/j.egyai.2022.100139>) in dem Journal Energy and AI

Gefördert durch:

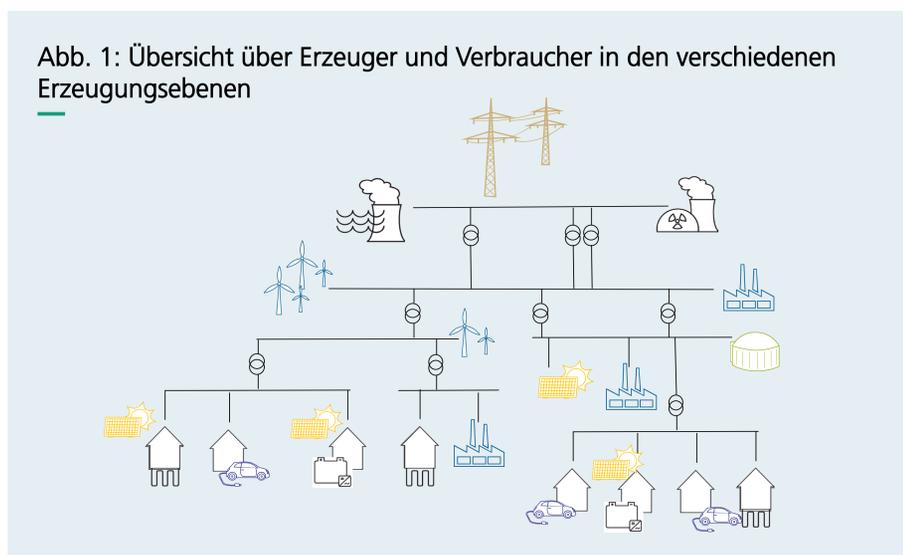
Disaggregation von Leistungsflüssen in der Niederspannung

D. Jost, D. Beinert, J. Koch, G. Good

Kontakt: Dominik Jost | +49 561 7294 467 | dominik.jost@iee.fraunhofer.de

Motivation

- Zahlreiche neue Verbraucher und Erzeugungsanlagen in der Niederspannung
- Verteilnetzbetreiber vermessen zunehmend die Leistungsflüsse an ihren Ortsnetzstationen
- Vorhanden Stammdaten stimmen oft nicht mit beobachteten Leistungsflüssen überein
- Verteilnetzbetreiber benötigen zum Netzbetrieb und zur Netzplanung bessere Informationen bezüglich der installierten Erzeuger und Verbraucher und deren tatsächlichem Verhalten



Aufgabenstellung

- Disaggregation der gemessenen Leistungsflüsse in ihre Bestandteile
- Identifikation der installierten Leistung bzw. der Anzahl von...
 - PV-Anlagen
 - Ladevorgängen von E-Kfz
 - Wärmepumpen
 - etc.

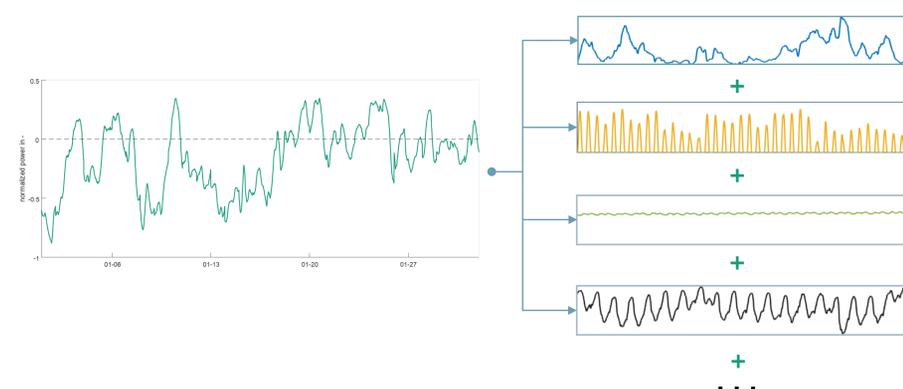


Abb. 2: Beispielhafte Zerlegung eines Leistungsflusses zwischen Hoch- und Höchstspannung in seine Bestandteile

Datengrundlage

- Messungen an den Abgängen von Ortsnetzstationen
 - Alle Phasen
 - Zeitliche Auflösung: 15 Minuten
- Geokoordinaten der Ortsnetzstationen
- Daten zur Validierung: z. B. bekannte Stammdaten

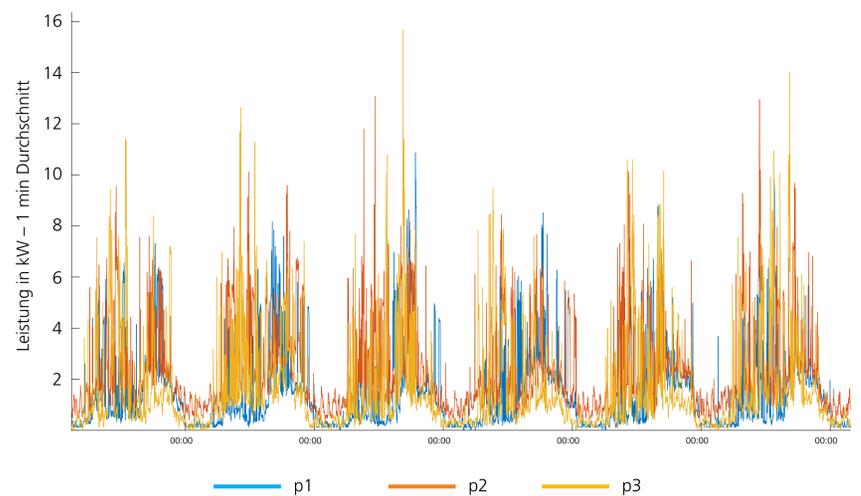


Abb. 3: Beispiel für den Leistungsflussverlauf an allen drei Phasen eines Ortsnetzstationsabganges

Stand der Wissenschaft und Technik

- Für die Zerlegung von Verbrauchszeitreihen von Haushalten gibt es verschiedene Ansätze. Hier liegt eine sehr geringe Aggregation vor und sogar der Verbrauch einzelner, auch kleinerer, Geräte kann identifiziert werden.
- Die Zerlegung von vertikalen Leistungsflüssen an Transformatoren zwischen Hoch- und Höchstspannungsnetz wurde in New4.0 mit GridFox umgesetzt. In diesem Fall überlagern sich die Erzeugung und Verbraucher einzelner Anlagen sehr stark, sodass die verschiedenen Erzeugungs- und Verbrauchsarten aggregiert betrachtet werden können.
- Die Disaggregation von Leistungsflüssen auf der Ebene von Ortsnetzstationen muss mit einer mittleren Überlagerung der einzelnen Erzeugungs- und Verbrauchersignalen umgehen können. Für diesen Zweck sind bisher keine Lösungen bekannt.

Projektpartner

- SMIGHT stattet bestehende Ortsnetzstationen mit Sensorik aus und stellt den Netzbetreibern die Messwerte online zur Verfügung.
- Im Projekt stellt SMIGHT Messwerte von ca. 30 Abgängen aus 5 unterschiedlichen Ortsnetzstationen bereit.

Gefördert durch:

EV Load Forecasting for Grid Operation

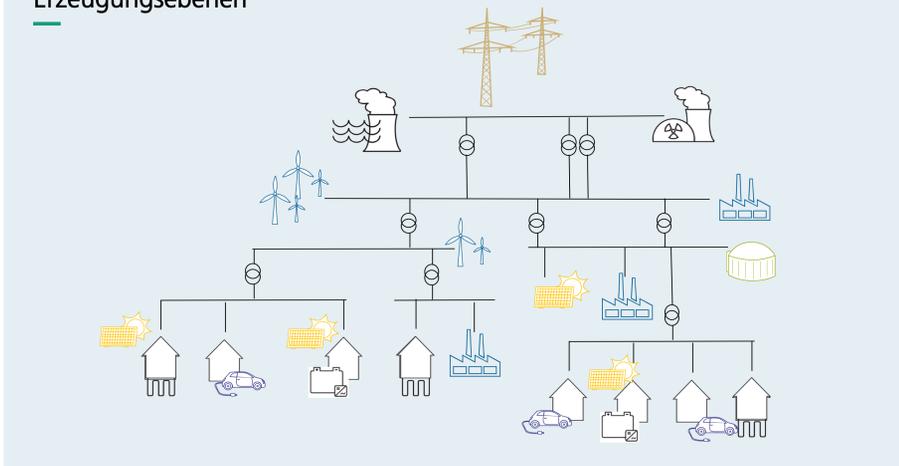
D. Beinert, J. Koch, G. Good, D. Jost

Kontakt: Dominik Jost | +49 561 7294-467 | dominik.jost@iee.fraunhofer.de

Ausgangssituation

- Elektromobilität erfährt starkes Wachstum.
- Laden der Elektroautos erzeugt hohe Leistungsbedarfe in Verteilnetzen.
- Verteilnetzbetreiber verfügen kaum über aktuelle Messwerte des Verbrauchs, weil Rollout von Smart-Metern stockt.
- Für Netzbetrieb werden zukünftig Prognosen des Verbrauchs in den Verteilnetzen benötigt (z.B. um Gebrauch von steuerbaren Verbrauchseinrichtungen §14a zu machen).

Abb. 1: Übersicht über Erzeuger und Verbraucher in den verschiedenen Erzeugungsebenen



Projektziele

- Erbringung des Proof-of-Concept, dass die Prognose der Ladeleistung für die nächsten Stunden auf Basis von Fahrzeugdaten möglich ist.
- Untersuchung des Mehrwerts von zusätzlichen GIS-Daten wie Ladesäulenstandorte, Straßenverläufe, Verkehrsflusszahlen.
- Bewertung der Nutzbarkeit der erzeugten Prognosen für den Netzbetrieb.

Stand der Wissenschaft und Technik

- Die Prognose der Ladeleistung an Ladestationen bzw. ortsfesten Stationen wird in zahlreichen Papern beschrieben (z. B. [1]).
- Fahrzeugdaten werden bisher vor allem verwendet, um Ladeprofile zu modellieren und den Netzausbau zu optimieren wie in [2] und [3].
- Eine Prognose der Ladeleistung auf Basis von Fahrzeugdaten ist nicht bekannt.

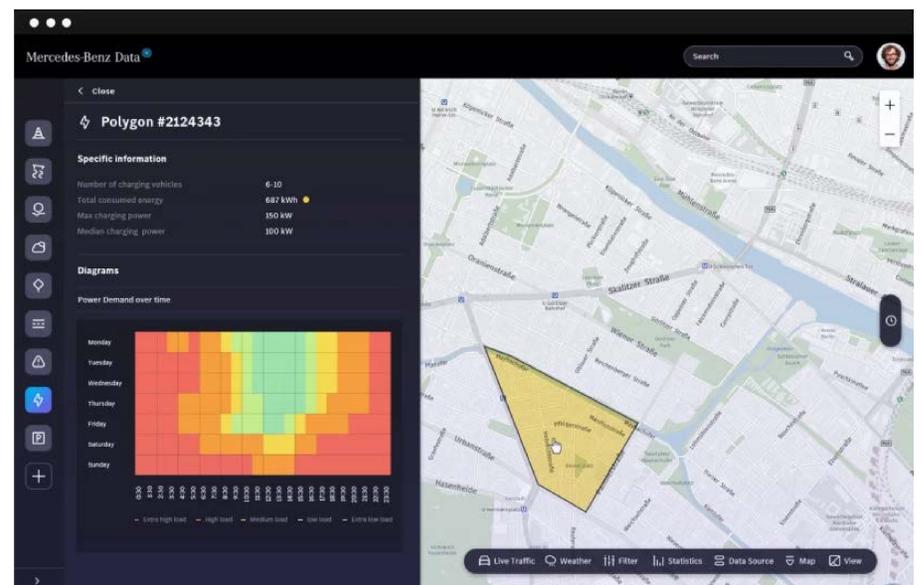


Abb. 2: Grafische Darstellung der »Energy Data« für ein Polygon (Quelle: Mercedes Benz AG)

Datengrundlage

- Fahrzeughersteller verfügen über eine breite Palette an Live-Daten aus ihren Fahrzeugflotten.
- Mercedes Benz als Projektpartner bietet unterschiedliche Datenprodukte an.
- Das Produkt »Energy Data« umfasst in anonymisierter Form pro Polygon:
 - Anzahl der Fahrzeuge
 - Maximale Ladeleistung
 - Durchschnittliche Ladeleistung
 - Gesamt geladene Energie
 - Gesamt geparkte Batteriekapazität

Methodik

- Problem aus Machine-Learning-Perspektive: Räumlich-zeitliche Sequenz-Prognose [4] gibt einen umfassenden Überblick von klassischen Methoden bis hin zu Deep-Learning-Verfahren zur Lösung dieses Problems.
- Geplant: Test verschiedener state of the Art Machine-Learning-Methoden wie
 - Generative Adversarial Networks (GAN)
 - pix2pix
 - Convolutional Neural Networks (CNN) kombiniert mit Long-Short-Term-Memory (LSTM)

1 Li, Y.; Huang, Y.; Zhang, M. Short-Term Load Forecasting for Electric Vehicle Charging Station Based on Niche Immunity Lion Algorithm and Convolutional Neural Network. Energies 2018, 11, 1253, doi: 10.3390/en11051253

2 Ashtari, E. Bibeau, S. Shahidinejad and T. Molinski, "PEV Charging Profile Prediction and Analysis Based on Vehicle Usage Data," in IEEE Transactions on Smart Grid, vol. 3, no. 1, pp. 341-350, March 2012, doi: 10.1109/TSG.2011.2162009.

3 C. Corchero, S. González-Villafranca and M. Sanmarti, "European electric vehicle fleet: driving and charging data analysis," 2014 IEEE International Electric Vehicle Conference (IEVC), 2014, pp. 1-6, doi: 10.1109/IEVC.2014.7056144.

4 Xingjian Shi, Dit-Yan Yeung, „Machine Learning for Spatiotemporal Sequence Forecasting: A Survey“, 2018, arXiv:1808.06865 [cs.LG]

5 Peng Xie, Tianrui Li, Jia Liu, Shengdong Du, Xin Yang, Junbo Zhang, Urban flow prediction from spatiotemporal data using machine learning: A survey, Information Fusion, Volume 59, 2020, Pages 1-12, ISSN 1566-2535, https://doi.org/10.1016/j.inffus.2020.01.002.

Gefördert durch:

GANs for Renewable Energy

M. Jürgens, C. Roelofs, B. Hoppmann, F. Rehwald

Kontakt: Björn Hoppmann | +49 561 7294-1606 | bjoern.hoppmann@iee.fraunhofer.de

Motivation

Getting reliable and anonymous data often is a crucial issue in research on wind turbines and their electric load profile. For this reason, this project aims to generate synthetic but realistic time series of wind turbine data using a GAN architecture. The main purpose is to improve anomaly detection due to the additional amount of realistic data. Besides that, the generated data can also be used for various other training purposes.

Generative Adversarial Networks (GANs) form a powerful framework for synthetic data generation and have predominantly been used to generate extremely realistic images. The usage of them in time series generation, however, has not been fully explored yet.

Generative Adversarial Networks

- Two neural networks, the Generator and the Discriminator perform a min-max game through simultaneous training
- Usage of additional conditions (time features, labels, locations), that are fed into both networks, improve the performance of the model as well as enable to generate more specified samples

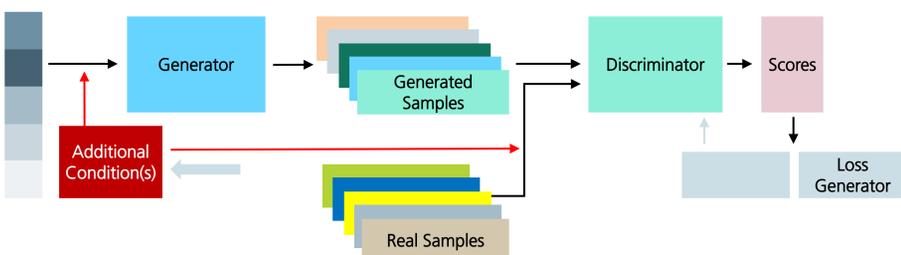
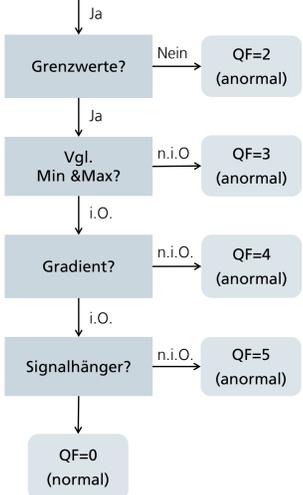


Figure 1: General Structure of a Conditional GAN (CGAN).

Data

The data used in the experiments all originate from the SCADA system of an offshore wind farm. Seven characteristics were used (wind speed, output power, wind direction, ambient temperature, pitch angle 1-3). All features were available as 10-minute averages and were preprocessed with the following steps:



- Flag samples as normal/anomalous (see Figure 2)
- Create sequences with 32 timestamps and an overlap of 31 timestamps
- Add conditions: anomalous/normal, timestamp embedding and location of wind turbines

Figure 2: Preprocessing pipeline for flagging time samples.

Evaluation

In order to evaluate the „realness“ of the synthetic time series samples, we made use of different criteria:

- Visual comparison: comparison of correlation heatmaps (auto-correlation as well as correlation between pairs of features), real and synthetic samples, histograms, and lower dimensional embeddings (t-SNE, PCA)

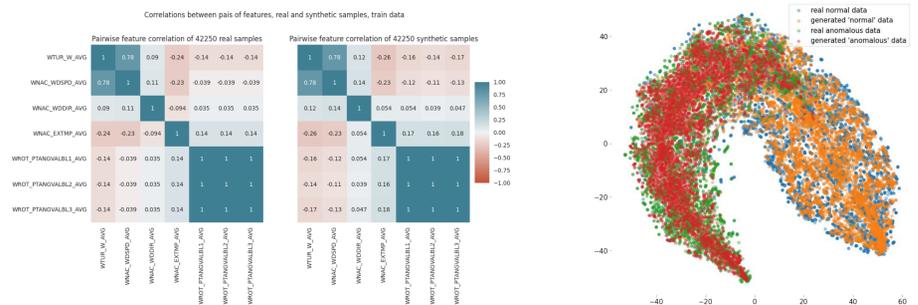


Figure 3: Correlation heatmaps between pairs of features for real data and data generated by a CGAN model.

Figure 4: t-SNE of real and synthetic samples labeled as normal (blue, orange) and anomalous (green, red).

- Maximum-Mean-Discrepancy:** Usage of a kernel-based statistical test measure to compare the distributions of real and synthetic data
- Train on Synthetic - Test on Real (TSTR):** Usage of external models (LSTM, Autoencoder) for prediction and classification tasks that are trained on the synthetic data, and then evaluated on the real data

	MMD	LSTM Predictive Score	AE Reconstruction Loss
Train data (real vs synth.)	0.05 ± 0.006	TRTR	0.0306
Validation data (real vs synth.)	0.31 ± 0.005	TSTR	0.0531
Validation and train data (real vs real)	0.28 ± 0.005		0.012

Figure 5: Different evaluation scores based on a three months training horizon, validated on a wind turbine unknown to the model. In a) the MMD between real and generated data is shown for the train data and validation data. In b) the prediction error of an LSTM, as well as the reconstruction error of an autoencoder is given for both TSTR and TRTR.

In this project, we developed a widely applicable CGAN model using an architecture specifically adapted to time series. Evaluation metrics and scores based on the TSTR principle indicate that the model is able to learn the distribution of the training data almost perfectly. However, when tested with features from data that the model has not seen before, there is a significant discrepancy in performance. It remains a challenging task to evaluate whether this is caused by overfitting to the training data or if the underlying structure was not actually learned.

Future work might include:

- Conditioning the CGAN to weather as a next step, which yields the potential to generate data for a whole wind park based on only two features.
- Using the already developed autoencoder model to further investigate anomaly generation and detection.

Gefördert durch:

Generation of Representative Artificial District Heating Systems

M. Wiemer, N. Asanalieva, P. Girón

Kontakt: Dr. rer. nat. Martin Wiemer | Telefonnummer: +49 561 0561 7294-1584 | martin.wiemer@iee.fraunhofer.de

Problem: Vertrauliche Behandlung benötigter Daten

Aufgrund der begrenzten Anzahl an Fernwärmeversorgungssystemen und ihrer Individualität sind deren Daten für Forschungszwecke schwer nutzbar und häufig nicht publizierbar, da anhand der sensiblen Daten die Zugehörigkeit zu bestimmten Versorgern erkennbar wäre.

Lösungsansatz: Nutzung KI-generierter, repräsentativer Systeme

Ziel des GRADS-Projekts

Unter Nutzung von KI-Methoden sollen für Forschungszwecke künstliche Beispielsysteme der Fernwärmeversorgung erzeugt werden, die gleichzeitig repräsentativ und verfremdet genug sind. Betrachtungsgegenstand hierfür sind kostenoptimale Pfade zur Dekarbonisierung¹, die via investSCOPE² erzeugt werden.

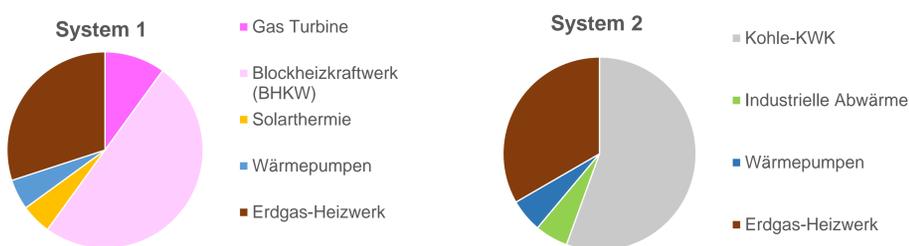


Abbildung 1: Zusammensetzung zweier künstlich erzeugter Fernwärmesysteme.

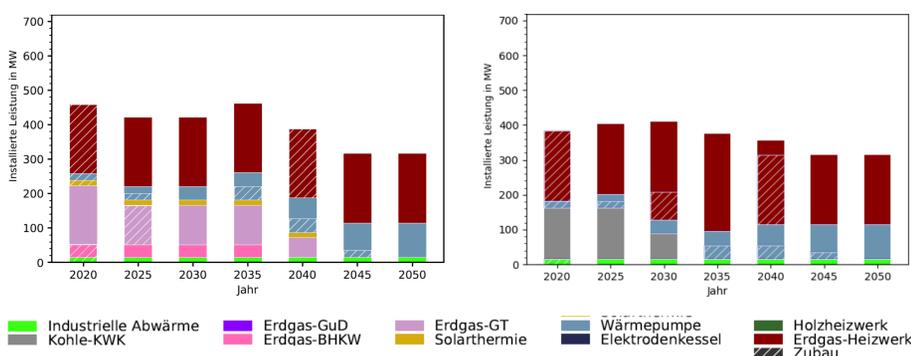


Abbildung 2: Kostenoptimale Pfade zur Dekarbonisierung mit investSCOPE für System 1 (links) und System 2 (rechts).

Daten von Fernwärmesystemen sind vertraulich zu behandeln

In GRADS zu verwendende Daten:

- Wärmelast (aggregiert): Lastgang oder Jahreslast/Spitzenlast
- Saisonal abhängige Vorlauftemperatur
- Anlagenportfolio (Technologie, Primärenergieträger, Leistungsparameter, Betriebskosten, Jahr der Inbetriebnahme, Lebensdauer, Investitionsanreize)
- Kraftstoffkosten
- Investitionskosten für Neuanlagen
- Potenziale (Niedertemperaturwärmequellen für Wärmepumpen, direkt nutzbare Abwärme, Freiflächen-Solarthermie)
- Zukünftiges System: Wärmelast, Vorlauftemperatur, optionale Technologien und deren Parameter.

Kriterien zur Bestimmung der Ähnlichkeit oder Unähnlichkeit von Eingabedaten

- Grundlegende Faktoren: Technologien, Zeitpunkte, Kosten
 - Anteil Wärmepumpen / KWK / Flexibilität (Erzeuger)
 - Speicherkapazität (insb. Saisonspeicher)
 - Anteil der Kapazität einzelner Technologien, der kurz-, mittel- oder langfristig ausgetauscht wird. Wobei hier nur Technologiewechsel betrachtet werden, nicht aber Anlagenwechsel
 - Investitionskosten, Betriebskosten (oder Verhältnis daraus) und Wärmegestehungskosten zu bestimmten Zeitpunkten
 - EE-Anteil

Konzept Toolentwicklung Generator

- Sensitivitätsanalyse mit Hilfe der KI: Eingrenzung der Einflussfaktoren, Input für Policy
- Toolentwicklung des Generators: Mit vereinfachter Optimierung (investSCOPE) über kurze Zeiträume
- Proof of Concept: Komplexere Optimierung (investSCOPE) über mehrere Dekaden
- Generierung der künstlichen Parameter via Monte Carlo Modell

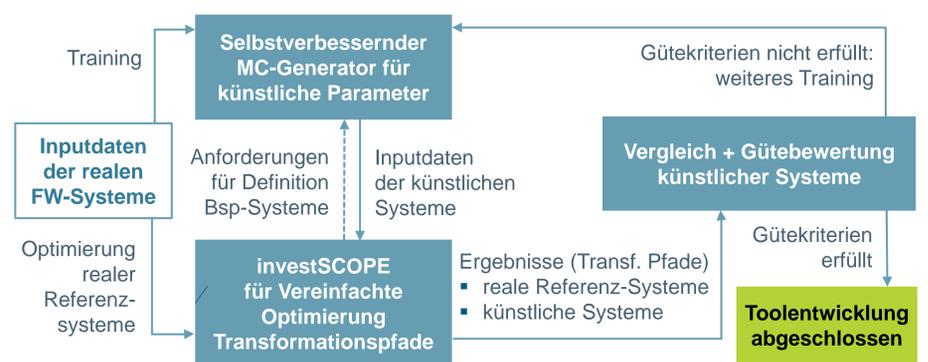


Abbildung 3: Interaktion der verschiedenen Elemente des Generators

Maß für Ähnlichkeit und Anonymität

- Definition von Vergleichsmaßen im Bereich von null bis eins, wobei 0 → »schlecht« und 1 → »gut«; zunächst individuell für jede Kennzahl
 - Beispiel Jahreslast: $S_l = \frac{|l_1 - l_2|}{l_1 + l_2}$
 - Beispiel Wärmegestehungskosten $S_c = 1 - \frac{|c_1 - c_2|}{c_1 + c_2}$
- Anschließend Bildung eines Maßes für Ähnlichkeit und eines Maßes für Unähnlichkeit unter Berücksichtigung von Gewichten
 - Beispiel Ähnlichkeitsmaß: $S_{sim} = \frac{\sum_{x \in \{similarities\}} w_x \cdot S_x}{\sum_{x \in \{similarities\}} w_x}$
 - Bildung eines Gesamtmaßes als finales Bewertungskriterium:

$$S_{tot} = \frac{w_{sim} \cdot S_{sim} + w_{ano} \cdot S_{ano}}{w_{sim} + w_{ano}}$$

Gefördert durch:

Kombination von Windleistungsprognosen

Jonas Koch, Alina Herzog, Dr. Axel Braun, Jens Hoppe, Vitalij Kasselmann, Wolfgang Slaby

Kontakt: Jonas Koch | +49 561 7294-1756 | jonas.koch@iee.fraunhofer.de

Eine der größten Herausforderungen bei der Leistungsprognose von nahezu vollständig wetterabhängigen erneuerbaren Energiequellen wie Wind und PV ist die Ungenauigkeit der verwendeten Wetterprognosen (Numerical Weather Prediction – NWP). Für den Energiemarkt sind diese Prognosen – insbesondere die Prognosehorizonte 0-4 h – essentiell. Unsicherheiten und Prognosefehler reduzieren bei Direktvermarktern die Gewinne oder führen zu Verlusten und gefährden bei Netzdienstleistern unter Umständen die Netzstabilität.

Auf dem Weg zu einem selbstlernenden Prognosesystem soll die Prognosegüte weiter verbessert werden, indem Kombinationsmethoden vorhandener Prognosen aus verschiedenen NWP getestet und in Echtzeit (re)kalibriert werden. Dazu wird ein zusätzliches Modell (häufige Updates, von IBM) herangezogen und dessen Mehrwert für die Kombination ermittelt.

Ziele

- Untersuchung des Mehrwertes des IBM GRAF Wettermodellblends für unsere Windleistungsprognose
- Entwicklung eines *continuous-delivery-for-machine-learning* (CD4ML) konformen Frameworks zur Kombination verschiedener Windleistungsprognosen durch unterschiedliche Methoden
- Passende Kombinationsmethoden auswählen und optimieren
- Optimierung der Parameter wie z. B. Länge des Trainingszeitraums oder Ermöglichen einer Bias-Korrektur
- Verbesserung der Prognosegüte
- Entwicklung robuster Verfahren, für den operativen Betrieb geeignet

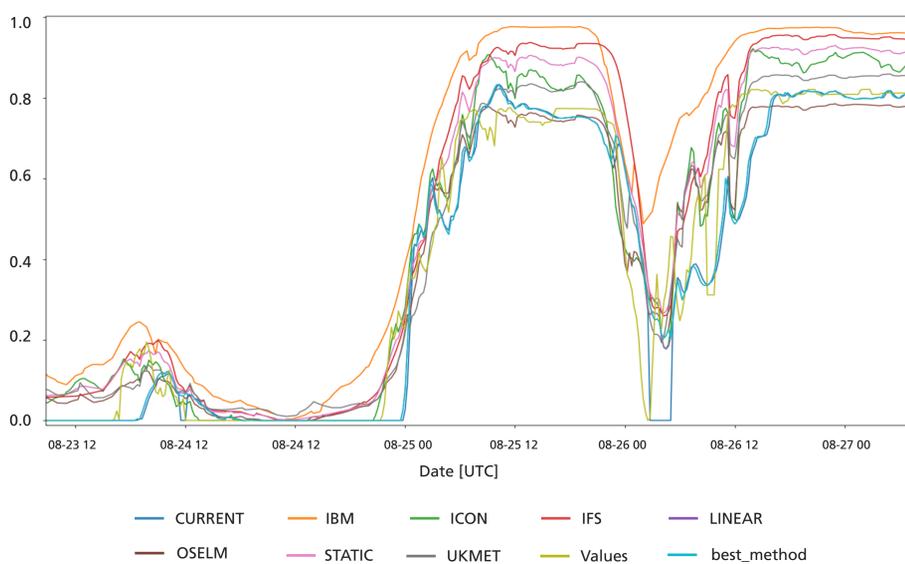


Abbildung 1: Unterschiedliche Verläufe von Wettermodellen und Kombinationen verschiedener Methoden

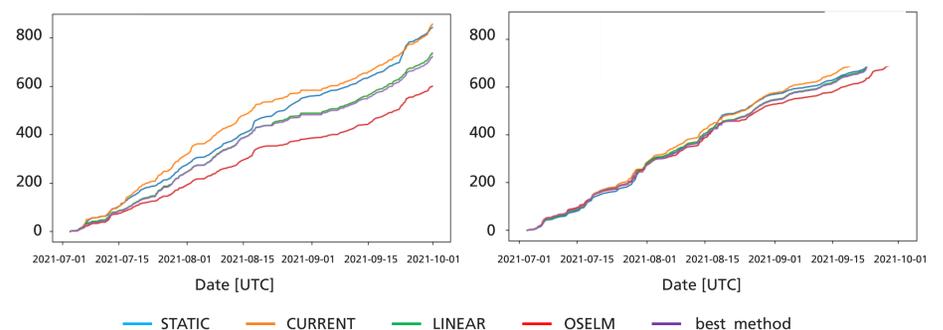


Abbildung 2: Kumulierter Fehler verschiedener Methoden für zwei verschiedene Windparks

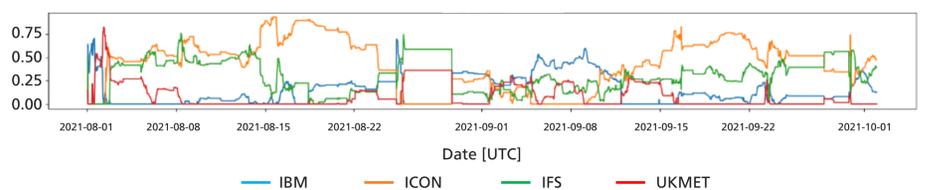


Abbildung 3: Gewichte für einzelne Wettermodelle bei einem gleitenden Trainingszeitraum von 7 Tagen

Ergebnisse

Performance Kombination

- Güteverbesserung / -verschlechterung stark parkspezifisch
- Parks mit stellenweise falscher Nennleistung und vielen Abregelungen profitieren am stärksten
- *Overfitting* kann zu schlechten Ergebnissen bei linearer Regression führen
- Güteverbesserung durch *Merge* über statische Gewichte hinaus herausfordernd
- Adaptive ML-Verfahren bereiten noch Probleme, *Online-Learning ELM* vorerst nicht robust genug für operativen Einsatz

Weitere Erkenntnisse IBM GRAF

- Performance der IBM-Leistungsprognose stark schwankend aber im Vergleich meist unterdurchschnittlich. Mögliche Gründe:
 - phys. Modell
 - kurze Historie -> phys. Modell nicht ausreichend kalibriert
- In *Merge* Methode aber mit stellenweise hoher Gewichtung (skaliert)
- »Verlauf« scheint gut zu passen, Amplitude nicht
- Mehrwert vorhanden

Lessons learned

- Bereits vorhandene Historie von Daten essentiell
- Anpassungen frei verfügbarer Methoden nötig
- Abfangen von Spezialfällen -> kostet viel Zeit
- Entwicklung für operativen Betrieb unterschätzt
- Nachhaltige Codeentwicklung mit hohem Initialaufwand
- Große Testabdeckung
- Verbesserungspotential zu optimistisch eingeschätzt

Gefördert durch:

Dominik Jost, Klara Reder, Alexander Dreher, Thomas Kanefendt, Jonas Koch, Malte Lehna

Kontakt: Dominik Jost | +49 561 7294-467 | dominik.jost@iee.fraunhofer.de

Temporal Fusion Transformer (TFT) were investigated to be used in time-series forecasting for several use cases in the energy context within the Competence Center for Cognitive Energy Systems. The project **HeatCast** evaluated whether TFT are suitable to forecast electricity and hot/cold water consumption of a manufacturing plant.

These forecasts offer the possibility to adjust the control of electricity and hot/cold water consumption resulting in reduced electricity and cooling water consumption and thus lower CO₂ emissions. This study shows a comparison of forecasts computed with both Extreme Learning Machines (ELMs) and TFT.

TFT (Temporal Fusion Transformer)

- Based on the principles of Transformer Networks and optimized for time-series forecasting
- Additional to NWP forecasts, **known future information** such as day-of-week, time-of-day, the position of the sun, and production targets can be incorporated into the forecast -> temporal patterns can be better identified
- In addition to the heterogeneous utilization of input data, the TFT also offers the possibility of
 - multiple-horizon forecasts and
 - probabilistic forecasts.

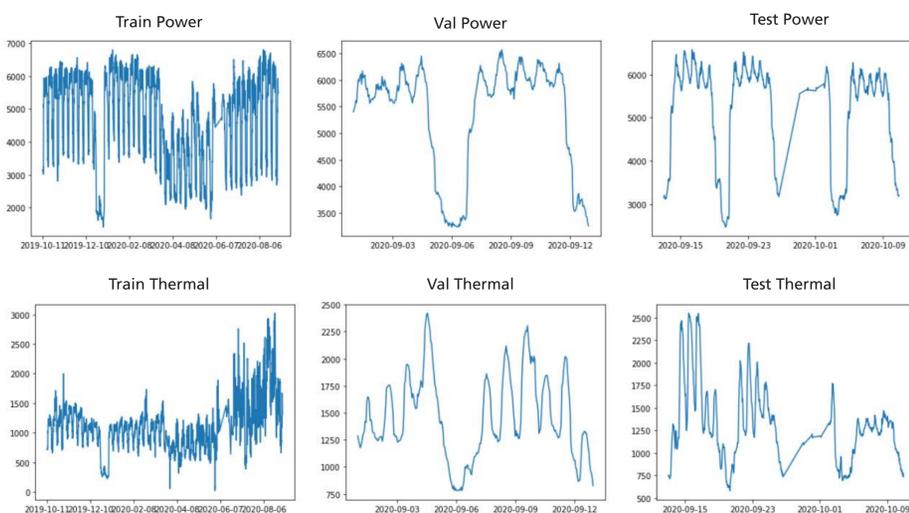


Figure 1: Plotting of time series.
Target data: training, validation and test period for power (top) and heat consumption (bottom)

Model Inputs

- Historical heat and power consumption time-series
- NWP parameter (wind-speed and direction, temperature, irradiance, ...)
- Lags and leads of parameters
- Known future information
 - Categorical variables (time-of-day, day-of-week, ...)
 - Position of the sun
 - Production targets

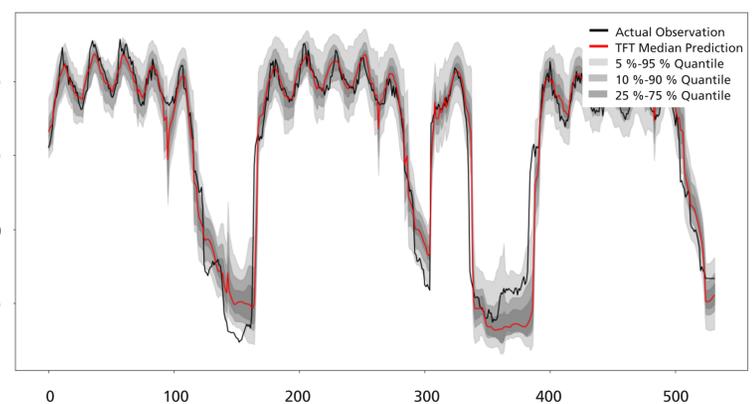


Figure 2: Probabilistic forecast example for power consumption

Results

Performance

- Power demand
 - Performance of TFT a lot better for both MAE and RMSE
- Heat demand
 - ELM and TFT with similar MAE
 - RMSE of ELM lower
- Differences nearly constant over forecast horizon

Feature importance

- Helps to explain the model and analyze the problem
- Helpful to reduce the number of input features
 - Required training period reduced
 - Reduction of training time
 - Better performance

Additional findings

- Multi-horizon forecasting trade-off between model reduction and performance
- Training-time of TFT magnitudes longer (GPU vs. CPU)
- TFT needs a lot of training data
- Probabilistic optimization reduces RMSE in some cases compared to the RMSE optimization
- Probabilistic forecasts reflect uncertainties very well
- Corona restrictions affected production a lot in the spring of 2020; the data could be used nevertheless

Conclusion

The results show that both methods (ELM/TFT) are suitable to forecast electricity consumption, as well as hot/cold water consumption. However, the forecast behavior differs and the methods have both advantages and disadvantages. With the used data at hand, the TFT model can not be recommended without restrictions for all problems within time-series forecasting. But the possibility to examine (to some extent) the feature importance (over time) within the TFT opens up further interesting findings.

Supported by:

Expert-Tool for Power Inverter Development

J. Steffen, D. Stracke, A. Seibel, F. Schnabel

Contact: Jonas Steffen | Fraunhofer IEE | +49 151 7449-6128 | jonas.steffen@iee.fraunhofer.de

Background

The new development of medium power converters (5 -100 kW) takes about 2-3 years with experienced developers and requires a lot of expert knowledge. Furthermore, the shortage of skilled workers has been increasing for years.

The InvEx | Expert-Tool for Power Inverter Development aims to accelerate and automate the development by supporting artificial intelligence. The main objective of the tool is to shorten the development time for control, topology and layout despite the lack of experts.

Overview of the Expert-Tool

- Toolbox for automatic layout and design of power converters
- Several complex topics are covered
- Connection to databases
- Intuitive user interface

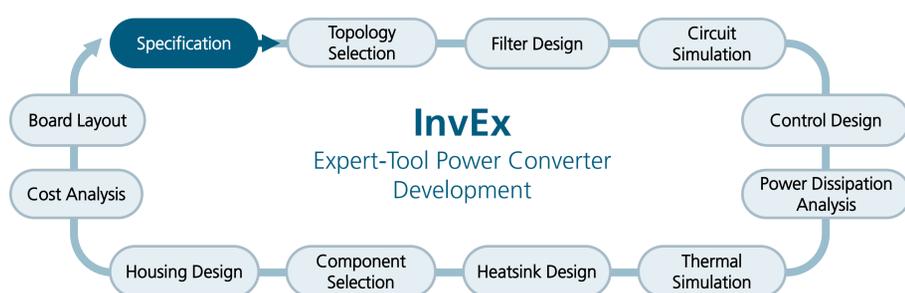


Figure 1: Schematic representation of the Expert-Tool. Main aspects of the converter development process are illustrated. The design of hardware, software and control technology is considered as a comprehensive approach.

Proof of concept

- Automatic design of switching frequency and DC link voltage
- Modeling of a single-phase battery power converter and application of Expert-Tool sub instruments
 - Filter Design
 - Circuit Simulation
 - Power Dissipation Analysis
 - Thermal Simulation
- Application profile of output power and air temperature characteristics
- Evaluation of annual lifetime consumption (LC) and line inductance
- Two-step procedure (according to Dragicevic¹)
 - Transfer of the complex simulation into a substitute model
 - Determination of LC over the year and inductance value

1. Dragicevic, T.; Wheeler, P.; Blaabjerg, F. Artificial Intelligence Aided Automated Design for Reliability of Power Electronic Systems. IEEE Trans. Power Electron. 2019, 34, 7161–7171.

1st Stage | Model Transfer

- Battery converter simulation is very complex
 - Simulation time of 1 s requires approx. 40 min computing time
- 375 parameter combinations of switching frequency f_{sw} , DC link voltage U_{DC} , ambient temperature T_a and instantaneous output power P
- Training of a neural network
- Use of the MATLAB Deep Learning Toolbox

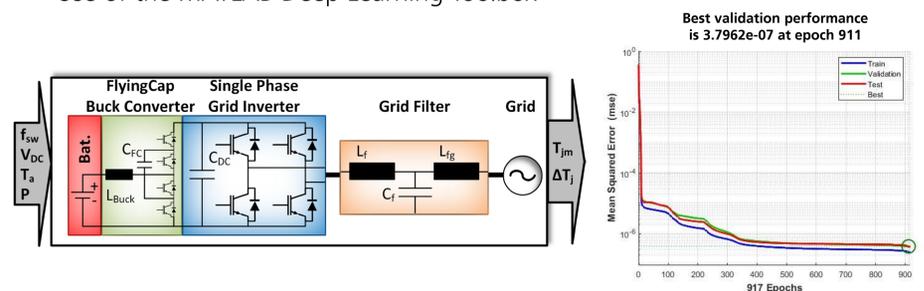


Figure 2: Single-phase battery power converter simulation model with input and output data, and the training results of the representation as a neural network.

2nd Stage | Automatic optimization of the battery power converter design

- Inclusion of curves of primary control demand and ambient temperature over one year
- Usage of the neural network of the battery power converter to calculate the annual trends
- Optimization for inductance and lifetime consumption
- Evaluation via a fitness function with different weights of the inductance

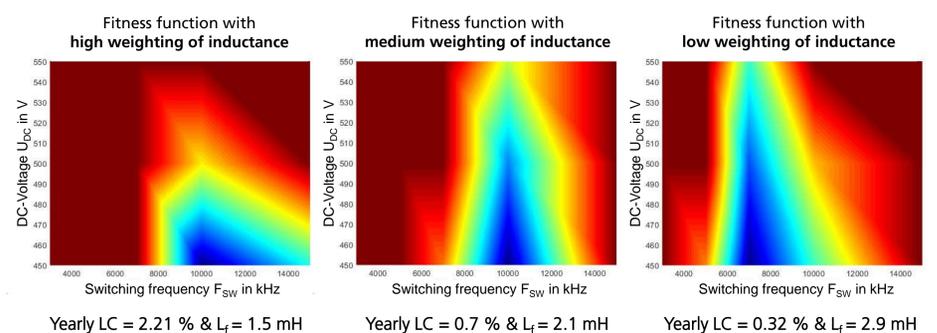


Figure 3: Evaluation of the annual trends on the representation of the fitness function with a weighting of lifetime consumption and inductance. The inductance was evaluated with different weightings.

Summary

- Outline specification of the Expert-Tool
- Proof of concept for selected features of the tool
- Use of neural network drastically reduces computation time
- Extension of the training of AI methods via automatic simulation and analysis scripts
- Further development and utilization of AI methods for additional points of the InvEx | Expert-Tool for Power Inverter Development

Supported by:

AI applied to Grid Operation

Malte Lehna, Clara Holzhüter, Phileas Vöcking, René Heinrich, Frank Marten, Alexander Scheidler, Christoph Scholz

Kontakt: Malte Lehna | +49 561 7294-1532 | malte.lehna@iee.fraunhofer.de

In den letzten Jahren wurden enorme Fortschritte in der Forschung im Bereich des verstärkenden Lernens gemacht. Dabei zeichneten sich die entwickelten Algorithmen durch ihre beeindruckende Fähigkeit aus, die Steuerung und Optimierung komplexer Systeme zu erlernen. Naheliegender ist also die Idee diese Methoden auch in der Netzbetriebsführung einzusetzen und die Entscheidungen des Leitpersonalpersonals mithilfe von KI zu unterstützen. Im Rahmen von KES wurden mehrere Spotlights entwickelt, um diesen Ansatz zu untersuchen und das Thema im Fraunhofer IEE und darüber hinaus zu platzieren.

KESL2RPN – Kognitive Energiesysteme Learn to Run a Power Network

Unter dem Namen »Learning to Run a Power Network« (L2RPN) wurde durch den französischen Netzbetreiber RTE eine Serie von Wettbewerben organisiert, deren Ziel es war, Agenten zu entwickeln die die Betriebsführung von Übertragungsnetzen übernehmen können. Um Netzengpässe zu verhindern, haben Agenten neben Redispatch-Maßnahmen auch die Möglichkeit durch Schalt-handlungen die Topologie des Netzes im Betrieb zu ändern.

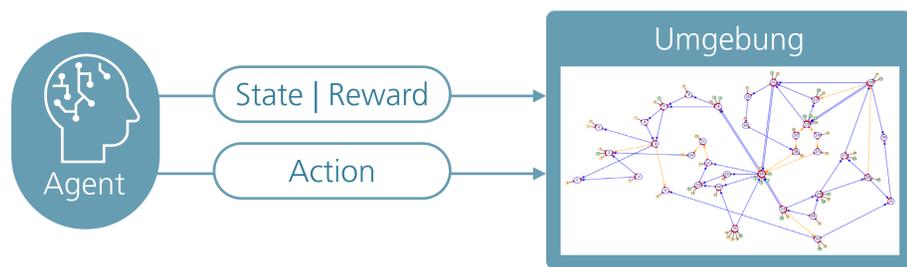


Abbildung 1: Schematische Darstellung der Interaktion zwischen Deep Reinforcement Learning Agenten und der Grid2Op Umgebung.

Im Rahmen des Spotlights 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 gesucht.

AI2GO4P

Im Rahmen eines Industrieprojektes wurden verschiedene Deep Reinforcement Learning Agenten aus der L2RPN Challenge zusammengeführt und weiterentwickelt. Hierbei sind deutliche Fortschritte erzielt worden, die in AI2GO4P sowohl als Open Source auf Github als auch in Form eines Papers veröffentlicht werden.

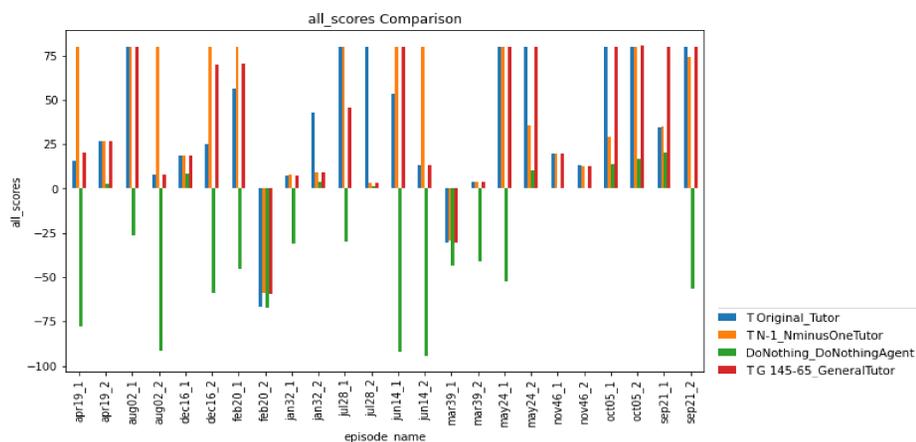


Abbildung 2: Die erreichten Belohnungen unterschiedlicher Agenten, die vom Fraunhofer IEE weiterentwickelt wurden.

ROSALIE – Grid2op Agent State Logging Investigation

In diesem Spotlight wurde in enger Zusammenarbeit mit RTE, die in den Wettbewerben genutzte Testumgebung »Grid2op« so erweitert, dass ein Zeitschritt wiederhergestellt werden kann, ohne den Agenten und die Umgebung komplett neu ausführen zu müssen.

GNN4PG - Graph Neural Networks for Power Grids

Ziel des Spotlights ist die Entwicklung einer auf das Stromnetz spezialisierten GNN Architektur, die das Stromnetz modelliert und eine geeignete Topologie und damit eine geeignete Regulierungsmaßnahme im Hinblick auf den Betrieb des Stromnetzes vorhersagt.

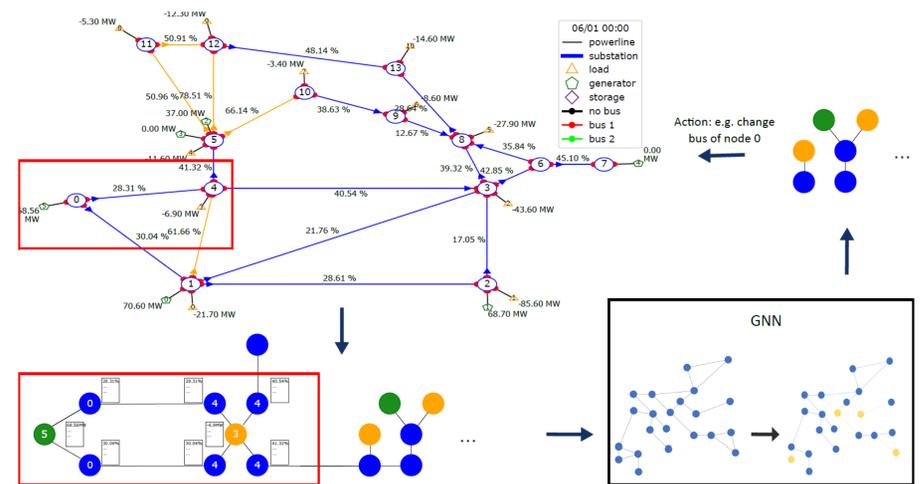


Abbildung 3: Das Stromnetz wird in eine Graphenstruktur transformiert, um diese für die Graph Neural Networks lesbar zu machen. Danach wird dann damit ein Agent trainiert, welcher auf Basis der Inputs einen regelbasierten Agenten imitiert.

Als Benchmark-Ansatz soll das GNN dabei mittels Supervised Learning auf der Erfahrung eines Greedy Agenten trainiert werden. Im erweiterten Ansatz wird eine direkte Topology Prediction in Form von Node Classification vorgenommen. Dabei wird für jeden Knoten eine Wahrscheinlichkeit ausgegeben, die angibt, ob der Knoten ein Kandidat für topologische Änderungen ist. GNNs haben den Vorteil, dass sie auf die inhärente Graphstruktur des Stromnetzes angepasst sind und korrelierte Komponenten durch die Aggregation verschiedener Knoten modellieren können.

So lassen sich Beziehungen zwischen Komponenten im Netz erlernen und Abhängigkeiten zwischen Komponenten darstellen.

Gefördert durch:

KI im Netzbetrieb – Chance für die Energiewende?

Zhenqi Wang, Alexander Scheidler, Sebastian Wende-von Berg

Kontakt: Dr. Sebastian Wende-von Berg | +49 561- 7294-298 | sebastian.wende-von.berg@iee.fraunhofer.de

Optimierung unter Unsicherheiten – KI-OPF1+2

Motivation

Neben den Unsicherheiten aus Erzeugungsprognosen beinhalten insbesondere vertikale Lastprognosen an Mittelspannungsumspannwerken eine große Streuung bzgl. ihrer P-Q-Abhängigkeiten. Die können ebenfalls zu Unsicherheiten an z. B. Netzverknüpfungspunkten zwischen HS- und HÖS-Netzen führen und damit auch in Betriebsmittelverletzungen wie z. B. Überschreitungen des Spannungsbandes resultieren.

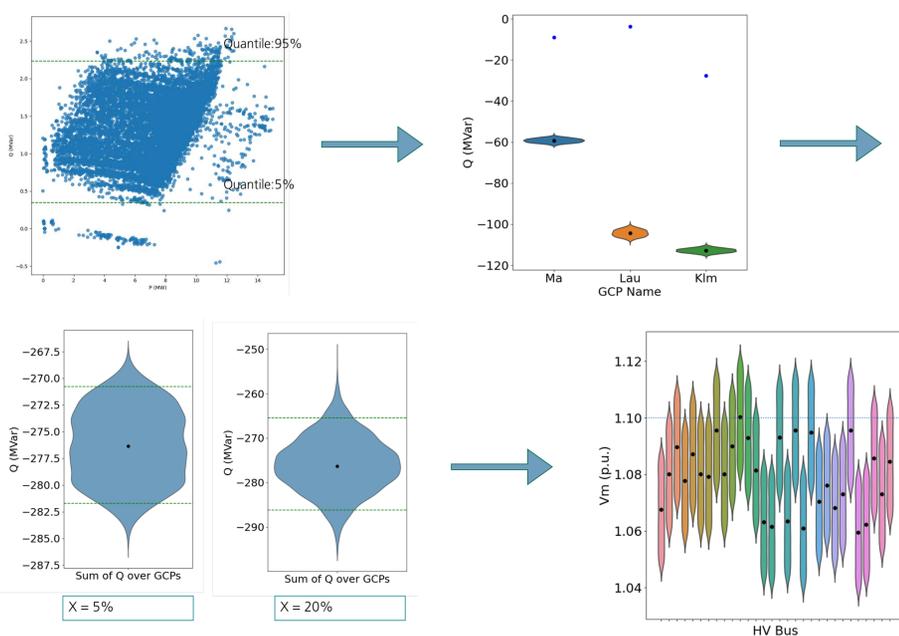


Abb. 1: Unsicherheiten in der P-Q-Abhängigkeit an MS/HS Umspannwerken (oben links) führen zu Unsicherheiten beim Einstellen fester Arbeitspunkte an Netzverknüpfungspunkten zwischen HS und HÖS (oben rechts). Diese wiederum summieren sich für ganze Netzgruppen/gebiete auf und führen zu signifikanten Abweichungen der Arbeitspunkte (unten links mit unterschiedlichen Unsicherheiten von 5% und 20%). Ebenfalls führen diese Unsicherheiten zu Abweichungen in den erwarteten Spannungsprofilen und können im Extremfall zu Betriebsmittelverletzungen führen.

Weiterhin müssen in einer Optimierung von Netzzuständen für den realen Netzbetrieb diverse Nebenbedingungen und Netzrestriktionen berücksichtigt werden. Neben den relativ gut zu modellierenden Bedingungen wie Spannungsgrenzen oder Leitungsauslastungen, stellt die Berücksichtigung von N-1 Ausfallsicherheit viele Optimierungen vor eine größere Herausforderungen. Insbesondere was die Rechenzeit und somit Echtzeitfähigkeit angeht.

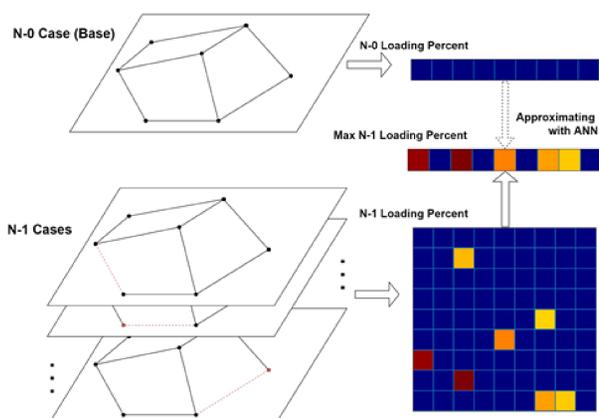


Abb. 2: Zerlegung der N-1 relevanten Netzsituationen, die dann von KNNs erlernt werden können und somit in einer späteren Optimierung berücksichtigt werden.

Umsetzung

In den Projekten KI-OPF1+2 wurden Ansätze zur Optimierung von Netzzuständen unter der Berücksichtigung von oben genannten Unsicherheiten und der Nutzung von Blind- und Wirkleistungsstellmöglichkeiten erneuerbarer Energieanlagen untersucht. Hierbei wurden künstliche neuronale Netze (KNN) auf Grundlage von probabilistischen Netzberechnungen trainiert. Neben den Unsicherheiten wurden zusätzlich auch Netzrestriktionen wie N-1 Sicherheit berücksichtigt und somit in einer späteren Optimierung gewährleistet. Dazu wurde ein kombinierter Ansatz aus überwachtem Lernen und selbstlernenden Algorithmen genutzt.

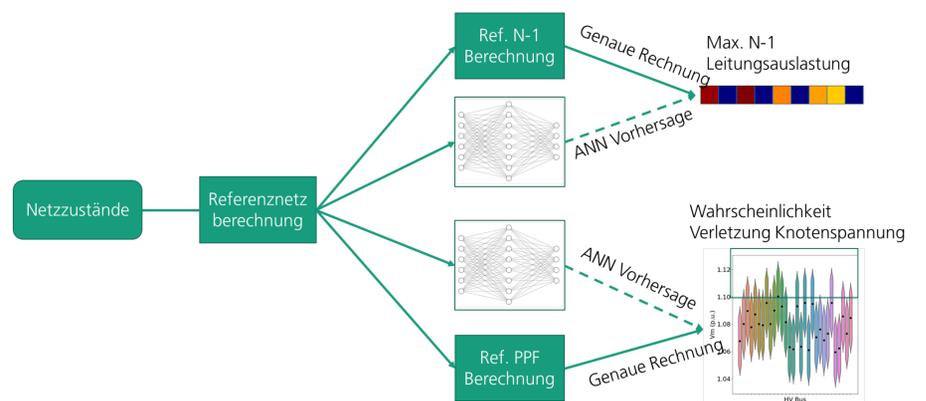


Abb. 3: Vereinfachter skizzierter Prozess des Trainings der KNNs. Diese KNNs werden später in den selbstlernenden Agenten überführt, so dass diese mit in der Optimierung berücksichtigt werden.

Dabei wird das nichtlineare Optimal Power Flow Problem für das überwachte Lernen formuliert und mithilfe gradientenbasierter Optimierung gelöst (Differential Programming). Der Agent lernt anschließend selbstständig geeignete Sollwerte für die Anlagen im Netz zu finden und kann durch die Kombination mit trainierten KNNs, Unsicherheiten und Netzrestriktionen berücksichtigen. Die trainierten KNNs werden mithilfe einer extrem hohen Anzahl von Netzberechnungen angelernet und beinhalten dann Informationen über N-1 Beschränkungen sowie mögliche Abweichungen der Netzzustände durch Fehler in Messungen und Prognosen.

Erste Ergebnisse und potenzielle Anwendung

Nachdem die Schätzungen der trainierten KNNs validiert wurde, konnte der KI-OPF auf einem Satz von Netzszenarien P-Q-Stellbereiche bestimmen. In der unteren Abbildung ist zu erkennen, dass der für den Netzbetrieb gültige Stellbereich unter Berücksichtigung von N-1 und Unsicherheiten im Training der KNNs die größte Fläche umfasst und somit das größte Flexibilitätspotenzial erfasst.

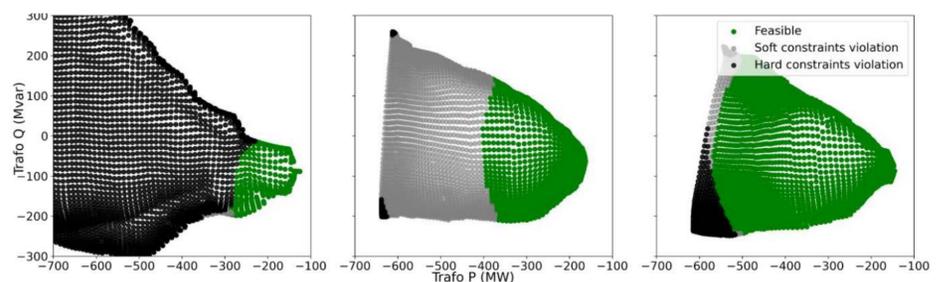


Abb. 4: Mögliche P-Q-Stellbereiche aus Optimierungsergebnissen unter den verschiedenen Trainingsgrundlagen für einen Netzzustand. (Die gesamte Fläche variiert aufgrund der unterschiedlichen Nebenbedingungen im Training der KNNs).

KI im Netzbetrieb – Chance für die Energiewende?

Mike Vogt, Kurt Brendlinger, Arne Wessel, Marcel Dipp, Malte Sievert, Sebastian Wende-von Berg

Kontakt: Dr. Sebastian Wende-von Berg | +49 561 7294-298 | sebastian.wende-von.berg@iee.fraunhofer.de

Probabilistische Netzzustandsprognose

Motivation

Deterministische Prognosen bzw. Erwartungswertprognosen bilden in der Regel die Grundlage für Netzzustandsprognosen im Engpassmanagement (Redispatch 2.0) des Netzbetriebes. Diese Prognosen berücksichtigen aber Unsicherheiten der Wetterszenarien nur wenig und wenn doch, dann meist in Form von durchschnittlichen Fehlern bzw. Abweichungen.

Ensemblebasierte Prognosen (z.B. auf 20 verschiedenen gleichwertigen Wetterszenarien) können hier genauere Unsicherheitsabschätzungen liefern und somit die operativen Engpassmaßnahmen effizienter, kostengünstiger und CO₂ sparer gestalten.

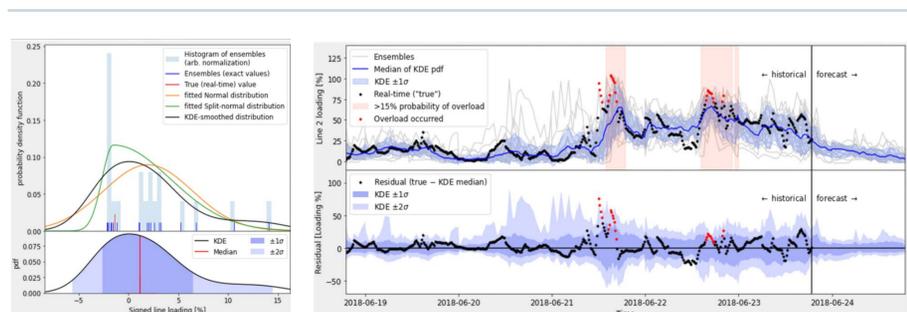
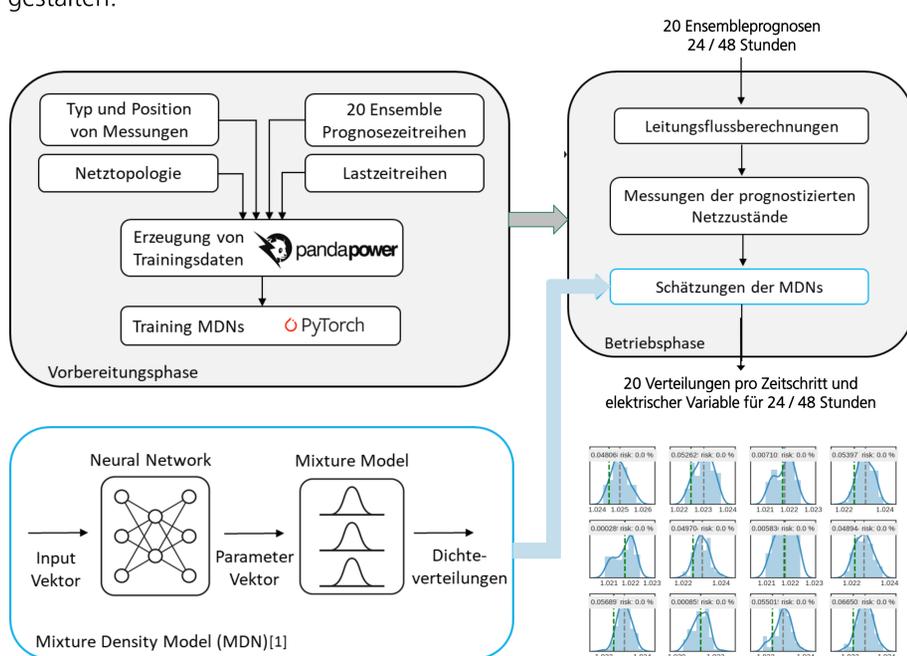


Abbildung 1: Der Weg von Ensembleprognosen über die Verarbeitung mit MDNs (obere Reihe) oder Glättungsfunktionen (untere Reihe) hin zu Netzzustandsverteilungen.

Umsetzung

In dem Projekt *Probabilistische Netzzustandsprognosen* wurden Ensembleprognosen, mithilfe von u.a. Multi-Density Networks und KDE Smoothing, zu Netzzustandsverteilungen verarbeitet. Diese werden dann über eine interaktive grafische Oberfläche dargestellt (siehe das [Video](#)).

NetzLupe – Optimierung auf Netzzustandsverteilungen

Optimierungsansätze

Um einen Mehrwert über das Wissen um diese Unsicherheiten bzw. Netzzustandsverteilungen zu erhalten, ist es nötig diese in Ansätzen zur Optimierung der Betriebsführung, wie das Engpassmanagement, mit einzubeziehen. In dem Projekt *NetzLupe* wurde mithilfe von Schalterstellungen anhand einer KI-basierten Optimierung versucht, Netzengpässe zu verringern bzw. zu vermeiden. Hierbei wurde ein selbstlernender Ansatz (Reinforcement Learning) gewählt, mit dessen Hilfe es möglich ist die Netzzustandsverteilung in die Optimierungsentscheidungen mit zu integrieren.

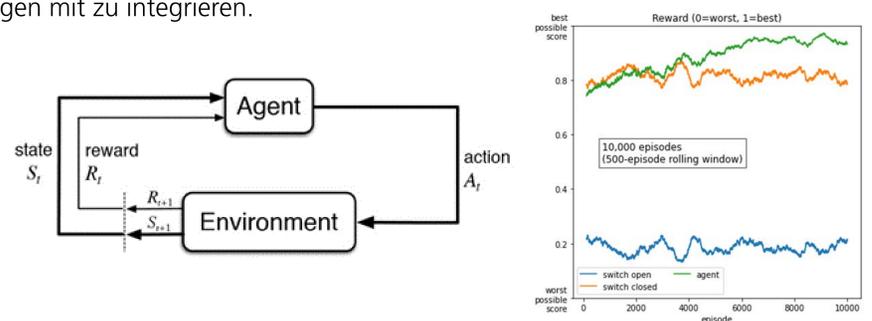


Abbildung 3: Links: Trainingsschema für selbstlernende Agenten. Rechts: Entwicklung des Agenten während der Trainingsperioden. Ab ca. 4000 Perioden zeigt der Agent durchweg bessere Ergebnisse als die konstanten Schalterstellungen »Auf« oder »Zu«.

Erste Ergebnisse

Es konnte gezeigt werden, dass Leitungsüberlastungen auf einfachen Netzen nur durch eine Rekonfiguration der Topologie verringert und sogar gelöst werden können. Hierbei wurde keine wertvolle Wirkleistung aus z.B. erneuerbaren Anlagen abgeregelt und somit konnte CO₂ an anderer Stelle eingespart werden.

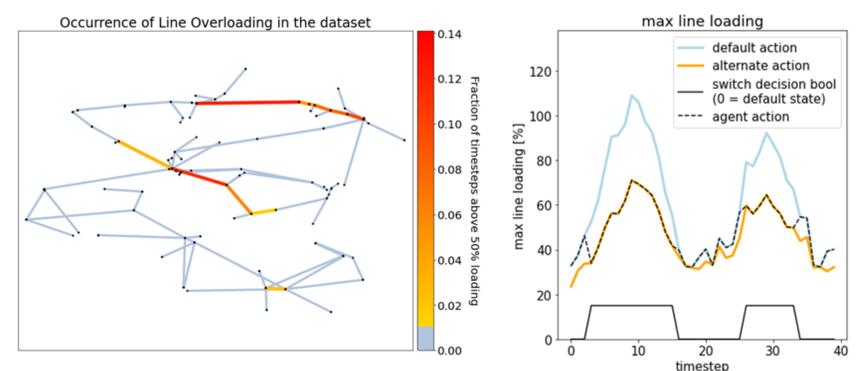


Abbildung 4: Links: Darstellung eines Testnetzes mit Leitungsüberlastungen. Rechts: Maximale Leitungsauslastung pro Zeitschritt einer Netzsimulation. Man sieht, dass der Agent durchwegs durch Schalthandlungen die Auslastung reduzieren kann.

Anwendung und Perspektiven

- Erkennen von alternativen Netzsituationen
- Bessere Einschätzung und Dimensionierung von Redispatchmaßnahmen
- Prädiktive Maßnahmenbestimmung um Netzengpässe im Vorfeld auszuschließen
- Optimierungsansätze um nur »bestimmte« Netzzustände zu realisieren
- Umsetzung der prototypischen Anwendung in eine operative Anwendung

Prognose von Leistungsflüssen im elektrischen Netz mit Graph Neural Networks

Dominik Beinert, Clara Holzhüter

Kontakt: Dominik Beinert | +49 561 7294-252 | dominik.beinert@iee.fraunhofer.de

Projektidee von PowerGraph

Die Leistungsflüsse im elektrischen Netz, die an Erzeugern wie Wind- und Photovoltaikanlagen, Verbrauchern oder an Transformatoren messbar sind, sind nicht voneinander unabhängig, sondern bedingen sich gegenseitig. Mithilfe von Graph Neural Networks (GNN) sollen die Beziehungen von Systemkomponenten untereinander erlernt und für die Prognose der einzelnen Leistungszeitreihen genutzt werden. Dabei soll aus vorhanden lokalen Features (Wetterprognosen, Verbrauchsprognosen, kalendarische Daten etc.) unter Berücksichtigung der benachbarten Knoten das gewünschte Knotenattribut (Leistungswert am Transformator) berechnet werden.

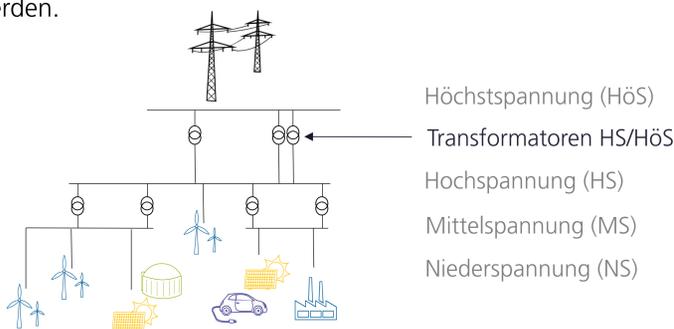


Abb. 1: Schematische Darstellung des elektrischen Netzes sowie der im Projekt untersuchten Transformatoren zwischen Hoch- und Höchstspannung

Motivation

- Machine-Learning Ansätze mit lokalen Modellen sind nicht in der Lage, Abhängigkeiten zwischen einzelnen Elementen im Netz zu berücksichtigen.
- Beispiel für Abhängigkeiten: Die Wartung eines Transformators kann dazu führen, dass ein oder mehrere „benachbarte“ Transformatoren dessen Aufgabe übernehmen und dadurch eine veränderte Zeitreihencharakteristik zeigen.
- Transformatoren im elektrischen Netz lassen sich durch einen Graphen darstellen, in dem ein Transformator durch einen Knoten repräsentiert ist, während die Kanten zwischen den Knoten anzeigen, ob zwei Transformatoren über elektrische Leiter miteinander verbunden sind.
- GNN können mehrere Eingangsmerkmale pro Knoten unter Berücksichtigung einer Adjazenzmatrix, die die Kanteninformationen des Graphen enthält, auf die jeweiligen Zielwerte abbilden.

Herausforderungen

- Unterschiedliches Zeitreihenverhalten an verschiedenen Trafos
- GNN erlernen typischerweise die gleich Prognosefunktion für alle Knoten → Ansatz: Kombination aus GNN und Embedding Multi-Task Learning
- Erlernen von Kantengewichten für stark vernetzten Graphen gestaltet sich schwierig → zunächst Annahme eines schwach vernetzten Graphen

Experimente

- Daten: 175 Trafos zwischen HS und HÖS (1 Jahr Training, 10 Monate Test)
- Nur Trafos am gleichen Standort sind über Kanten verbunden
- Bayesian Embedding als Multi-Task Learning Ansatz
- Attention Convolution (TransformerConv) als GNN Layer

Ergebnisse

- Beste Performance wird mit attention-based GNN erzielt
- Korreliertes Verhalten von Trafos bei schwach vernetztem Graphen erlernt

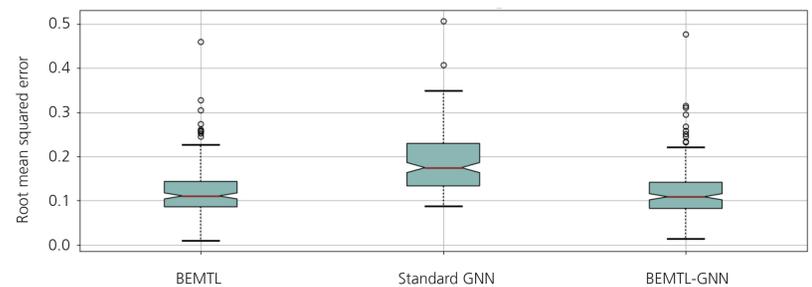


Abb. 2: Testfehler (Root Mean Squared Error) des Benchmarkmodells Bayesian Embedding Multi-Task Learning (BEMTL), eines Standard-GNNs und der im Projekt entwickelten Methode BEMTL-GNN

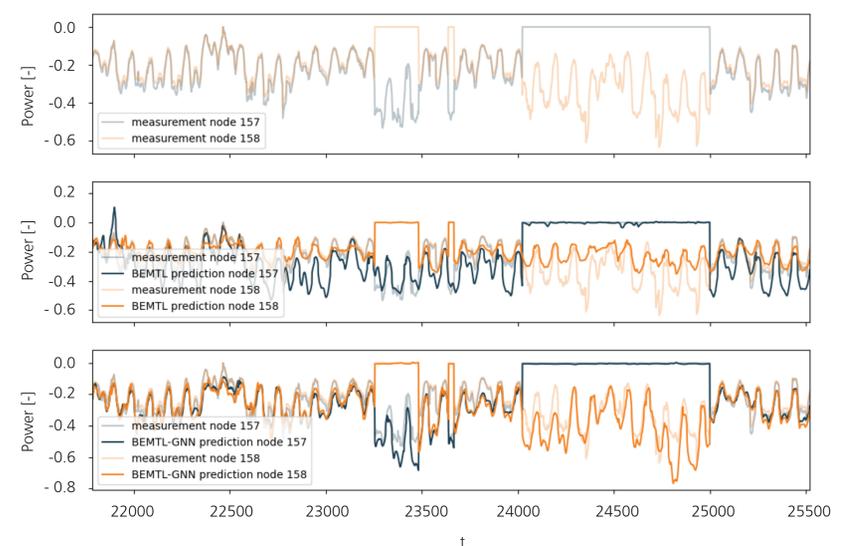


Abb. 3: Leistungsflussprognosen des Benchmarkmodells BEMTL (Mitte) und des im Projekt entwickelten Modells BEMTL-GNN (unten) an zwei Transformatoren

Fazit und Ausblick

- Proof of Concept gelungen
- Unser GNN führt zu einer leichten Verbesserung des Testfehlers und einer deutlichen Verbesserung des Prognoseverhaltens
- Erlernen von Ausgleichsverhalten bisher nur bei schwach vernetzten Graphen möglich → Forschungsbedarf
- Erweiterung: zusätzlich Erzeuger / Verbraucher im Graph darstellen
- Geplantes Paper in Energy and AI special issue Smart Grid and AI

A. Dreher, L. Martmann, M. Lehna, C. Roelofs, S. Liebehentze, R. Brandl, J. Dobschinski, J. Koch, L. Pauscher, S. Wende-von-Berg

Kontakt: M.Sc. Alexander Dreher | 0561-7294-1750 | alexander.dreher@iee.fraunhofer.de

Im Projekt **SmartChargingPilot** wurde die Funktionsfähigkeit von Algorithmen des maschinellen Lernens für das Lademanagement von Elektrofahrzeugen (E-Kfz) erprobt. Für zwei unterschiedliche Anwendungsfälle im Heimenergiemanagement und Fuhrparkmanagement wurden innovative selbstlernende Algorithmen entwickelt, die Flexibilitätspotenziale im Lademanagement nutzen, um Ladevorgänge intelligent zu steuern.

Problemstellung

Das intelligente Lademanagement (*Smart Charging*) ist eine Klasse von Energiemanagement-Problemen, die sich mit dem optimalen Laden von E-Kfz beschäftigt. In dem Spotlight-Projekt SmartChargingPilot wurden dabei zwei Anwendungsfälle betrachtet. Im ersten Schritt wurden eine Simulationsumgebung und Algorithmen für ein Heim-Energiemanagement-System (HEMS) entwickelt, welches neben typischen Endkundeneinrichtungen auch eine steuerbare Ladestation berücksichtigt. Im zweiten Schritt wurden Algorithmen für das Management mehrerer Ladestationen für einen Unternehmensstandort entwickelt.



Abbildung 1: Untersuchte Anwendungsfälle des Smart Charging

Methodik: Reinforcement Learning

Ein innovativer Ansatz das Smart Charging Problem zu lösen, ist die Anwendung von Deep Reinforcement Learning (DRL). Dabei werden Methoden des Reinforcement Learning (RL) mit tiefen neuronalen Netzen kombiniert. Beim RL lernt ein Agent durch Interaktion mit seiner Umgebung. Jedes Mal wenn der Agent eine gewählte Aktion durchführt, verändert sich seine Umgebung und gibt ihm ein numerisches Belohnungssignal (siehe Abbildung 2). Über dieses Signal optimiert der Agent im Training schrittweise seine Strategie. Da DRL ein datenbasierter Ansatz ist, wird kein exaktes Modell der Umgebung benötigt.

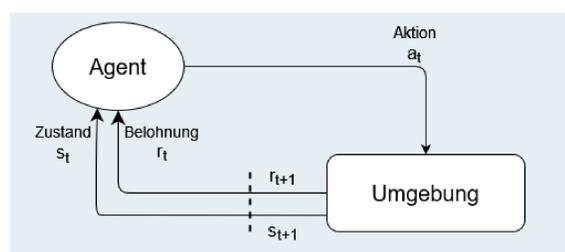


Abbildung 2: Interaktion eines Reinforcement Learning Agenten mit seiner Umgebung

Modellierung

Für das Heim-Energiemanagement wurde ein Einfamilienhaus mit PV-Anlage, Batteriespeicher, Wärmepumpe und einem E-Kfz und deren Erzeugung / Verbräuche modelliert. Ziel des RL-Agenten war es, die Leistungsauf-/entnahme der Wärmepumpe, des Batteriespeichers und des E-Kfz optimal zu steuern, um die Energiekosten zu senken. Anschließend wurde für weitere Untersuchungen ein Ladeszenario für Unternehmensstandorte modelliert.

Die Modellierung bestand aus der Abbildung von 6 Ladesäulen, die an den Werktagen von verschiedenen E-Kfz besucht werden konnten. In Anlehnung an die Ergebnisse des Leuchtturms MobiCast wurden verschiedene Benutzerverhalten simuliert, die sich u.a. in An-/Abfahrtszeiten, gefahrener Strecke und präferierter Ladesäule unterschieden.

Ergebnisse

Abbildung 3 zeigt Resultate eines trainierten RL-Agenten, welcher das Lademanagement für ein Elektrofahrzeug, das Speichermanagement eines Heimspeichersystems sowie die Steuerung einer Wärmepumpe erlernt hat.

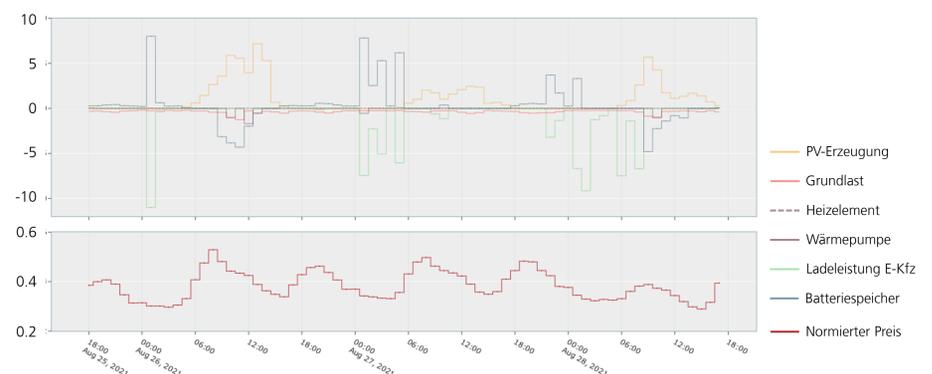


Abbildung 3: Beispiel der Ergebnisse des RL-Algorithmus für das intelligente Lade- und Energiemanagement eines Haushalts

Gut zu erkennen ist, dass der Agent die Haushaltslasten, einschließlich des Batteriespeichers, so koordiniert, dass sie den durch die PV-Anlage eigenerzeugten Strom optimal aufnehmen. Weiterhin wird der Batteriespeicher koordiniert entladen, um die Last zu bedienen, welche durch die Wärmepumpe in Stunden entsteht, in denen kein PV-Strom erzeugt wird. Schließlich wird auch ersichtlich, dass der RL-Agent hohe Preisspitzen vermeidet, indem erforderliche Netzbezüge in Strompreistälern bedient werden¹.

Während der Agent im Unternehmensstandort-Szenario ebenfalls Fortschritte im Training zeigte, waren die Ergebnisse beim Test auf ungesehenen Daten nicht eindeutig. Hier zeigt sich der Blackbox-Charakter der RL-Methodik, der in Folgeaktivitäten adressiert werden soll.

Fazit und Ausblick

Das Spotlight-Projekt zeigt das hohe Potenzial der DRL-Algorithmen für eine dezentrale, ressourcengünstige und datenbasierte Lösung auf. Gleichzeitig wurden Herausforderungen identifiziert, wie die Ausgestaltung geeigneter Anreize bei mehreren konkurrierenden Zielen sowie die Ergebnisunsicherheit, welche durch den Blackbox-Charakter von RL entsteht. Auf Basis der Erkenntnisse wird nun ein Best-Practice-Factsheet für den DRL-Einsatz in energiewirtschaftlichen Anwendungsfällen entwickelt. Weiterhin wird ein von konkreten Anwendungsfällen abstrahierender Ansatz für eine optimale Evaluierungsstrategie abgeleitet, um dem RL-Blackbox-Problem zu begegnen.

¹ AI agents assessing flexibility: the value of demand side management in times of high energy prices <https://doi.org/10.1109/EEM54602.2022.9920982>

Intelligent partial discharge evaluation with Machine Learning Methods

S. Lengsfeld, F. Rehwald

Kontakt: Florian Rehwald | +49 561 7294-448 | florian.rehwald@iee.fraunhofer.de

Motivation

As a result of the privatization of the energy market and the associated increase in price pressure, the need for service life extensions and load optimization of components from the energy supply system has risen sharply in recent years. For this reason, the assessment of component conditions, especially the diagnosis of insulation systems, is becoming increasingly important.

Data preprocessing

- Phase Resolved Partial Discharge (PRPD) images were used as input for the classifier (Figure 1)
- The color scaling in the images may vary
 - Transformation into a uniform format is necessary (Figure 2)

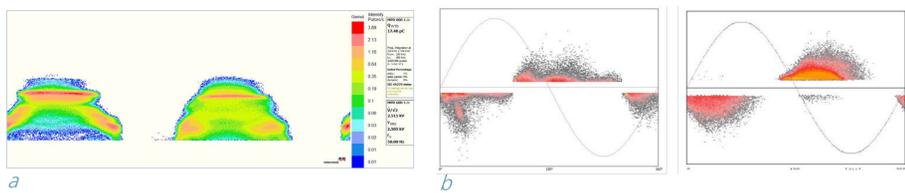


Figure 1: Example images of PRPD diagrams ; (a) own measurement (b) IEC TS 60034-27-2:2012

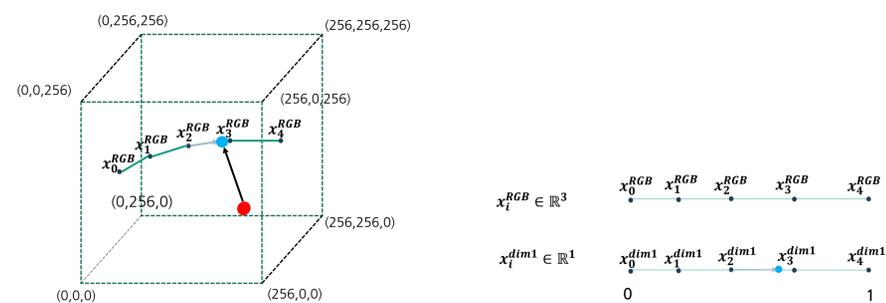


Figure 2: Dimensional reduction from RGB space to one-dimensional space

Data augmentation

- Based on the seven types of partial discharge patterns for each pattern, 400 images were generated to train and test the classifier
- Both online and offline measurements were used for each type

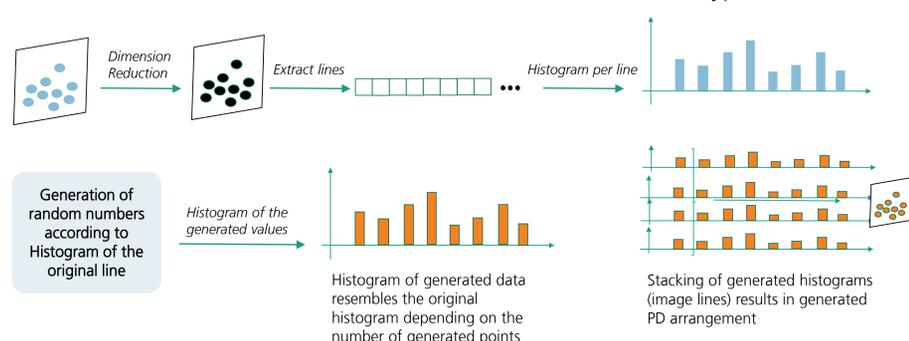


Figure 3: Resampling process for data augmentation

Partial Discharge Types

- 7 classes of Partial Discharge Patterns were defined in accordance with IEC TS 60034-27-2:2012 and IEC TS 60034-27-1:2017 (Figure 4).

Cat 1	Partial Discharge at Winding Ends		Internal Partial Discharge			Slot Discharge	
Cat 2	Online						
	Offline						
Cat 3	Phase to Phase	Surfaces Discharges	Gap Type Discharges	Delamination between conductors / insulation	Internal Delamination	Inner hollow space discharges	Slot Discharge
Cat 4	- online	- online	- online	- online	- online	- online	- online
	- offline	- offline	- offline	- offline	- offline	- offline	- offline

Figure 4: Categories for classification used in the CNN based on different partial discharge phenomena and measurement techniques in rotating electrical machines

CNN-Classifer

A classic CNN setup was followed along the lines of M. Florkowski (2020) tracked

- Conv2D-layer: kernel = 5x5, stride=(1,1)
- Max-pooling-layer: kernel = 2x2, stride = kernel size (2,2)
- Activation function: ReLu (Conv2D-layer and fully-connected-layer)

Results & Conclusion

- The classifier was reliably able to distinguish the 3 main classes. For more than that the accuracy was still 84.5 %, but nevertheless reliable. (Tbl. 2)
- One challenge is the lack of measurement data, so the quality of the algorithm depends on data augmentation.
- The model could only conditionally distinguish between classes zero, three and five, which can be attributed to the similarity of the PD patterns. (Figure 5, Tbl. 1)

Predicted Class	Target Class						
	1	2	3	4	5	6	7
1	4	0	1	8	0	9	0
2	0	34	0	0	0	0	0
3	0	0	31	0	0	0	0
4	0	0	0	31	0	0	0
5	0	0	0	0	29	0	0
6	0	1	0	1	1	7	0
7	0	0	0	0	0	0	33

Table 1: Confusion matrix of model 4 showing the target class compared to the predicted class

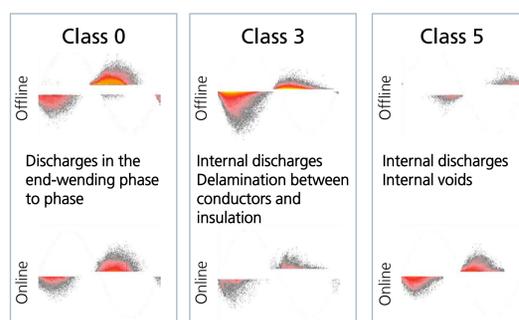


Figure 5: Plots of the patterns of class 0, 3 and their difference in offline/online measurement.

Model	Classes	Test Accuracy in %
Model 1	3	100
Model 2	3	83.5
Model 3	3	83.5
Model 4	7	84.5
Model 5	7	64
Model 6	7	70

Table 2: Training behavior and performance of the studied architectures

Temporal Fusion Transformer

Jonas Koch, Malte Lehna, Leon Franken

Kontakt: Jonas Koch | +49 561 7294-1756 | Jonas.koch@iee.fraunhofer.de

Temporal Fusion Transformer (TFT) were investigated to be used in time-series forecasting for several use cases in the energy context within the Competence Center for Cognitive Energy Systems. In this case, the usability for probabilistic wind power forecasts was investigated.

The focus was placed on the simultaneous training and prediction of several wind parks within one model in order to make spatio-temporal dependencies available to the model and to evaluate the performance.

TFT (Temporal Fusion Transformer)

- Based on the principles of Transformer Networks and optimized for time-series forecasting
- Additionally to NWP forecasts, **known future information** such as day-of-week, time-of-day can be incorporated into the forecast -> temporal patterns can be better identified
- Easy to group/tag information belonging to one location while training several
- In addition to the heterogeneous utilization of input data, the TFT also offers the possibility of
 - multiple-horizon forecasts and
 - probabilistic forecasts.
- Attention can help to understand the model better (XAI)

Model Inputs

- Wind power generation of one or several wind parks
- NWP parameter (wind-speed and direction, temperature, irradiance, ...)
- Lags and leads of parameters
- Known future information
 - Categorical variables (time-of-day, day-of-week, ...)

Feature importance

- Helps to explain the model and analyze the problem
- Helpful to reduce the number of input features
 - Required training period reduced

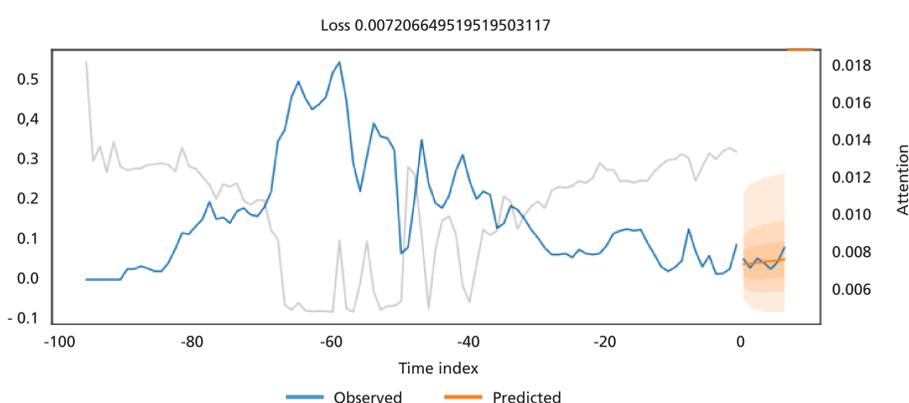


Figure 1: Attention plot showing the time-dependent importance of the variables (here for one time-step). Measurements in blue and attention in grey.

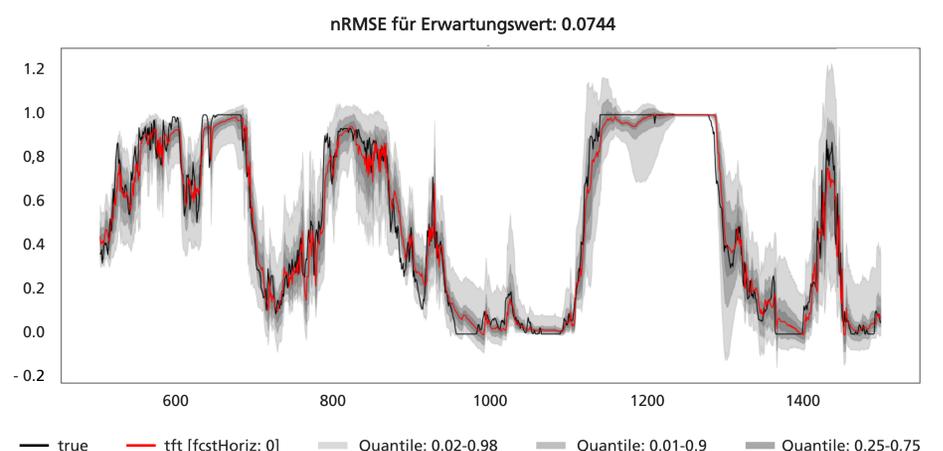


Figure 2: Probabilistic forecast example for one wind park

Results

Performance

- Outperforms the operative model for very short-term horizons
- Forecasts not "pulled towards the mean"
- Decreased performance for longer horizons
- Probabilistic forecast reflects uncertainties very well
- Profits if several parks are used for the model

Additional findings

- Multi-horizon forecasting trade-off between model reduction and performance
- Training time of TFT magnitudes longer than e.g. ELM
- TFT needs a lot of training data
- Without further steps (transfer-learning) not yet scalable for a huge amount of parks

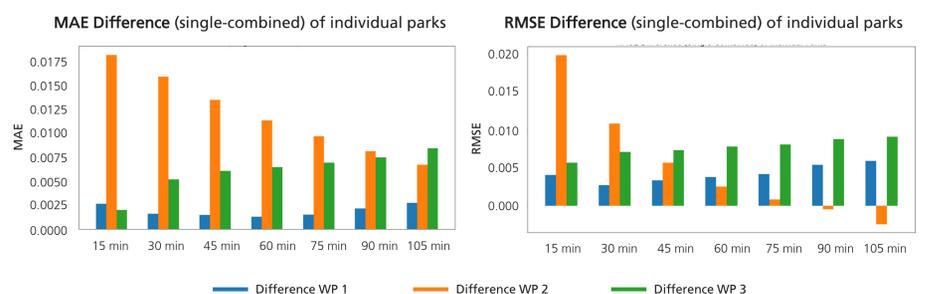


Figure 3: Decreasing performance gain with offsite information for three wind parks over the forecast horizons

Conclusion

The results show that the TFT is a method capable of generating well-performing forecasts. Especially the gain in the usage of offsite information is considerable but depends on the specific park and decreases quickly with the forecast horizon. The caveat of the model is its complexity and in comparison to methods like ELM considerably longer training times.

Supported by:

Technical Language Processing für Instandhaltungsinformationen in Fernwärmesystemen

E. Guevara Bastidas, A. Lutz, H. Dittmer, A. Kallert

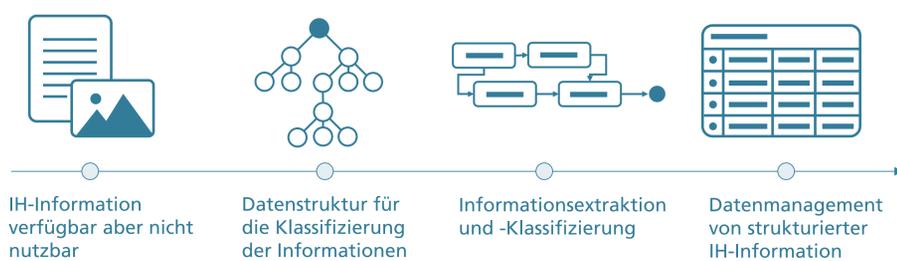
Kontakt: Edison Guevara Bastidas | Telefonnummer: +49 561 7294 1583 | email: edison.guevara@iee.fraunhofer.de

Executive Summary

Für die effiziente Instandhaltung von Fernwärme-Hausstationen sind die Instandhaltungsinformationen (IH-Informationen) in bspw. Serviceberichten eine erforderliche Grundlage, denn sie enthalten die Schlüsselinformationen, die für strategische Entscheidungen sowie die Entwicklung von Modellen zur Fehler-früherkennung notwendig sind. Allerdings sind diese Informationen meist nicht verwertbar, da sie nicht digitalisiert und unstrukturiert vorliegen. Ziel des Projekts TLP4Heat ist die Erarbeitung einer Methodik, welche die IH-Informationen für die Entwicklung optimaler Instandhaltungsstrategien analysierbar macht.

Methodik

- Bestandsanalyse der IH-Informationen sowie Überprüfung der relevanten technischen Regelwerken in der Fernwärme, um die Schemata für die Klassifizierung von Komponenten und Maßnahmen zu identifizieren
- Aufbereitung und Annotation der Daten mit Methoden des *AI-Assisted-Tagging* insbesondere mit dem Tool *Nestor* vom *National Institute of Standards and Technology*
- Entwicklung der Klassifikatoren: Random-Forests mithilfe von Sklearn und Neuronen-Netze mithilfe von Keras. Dies konnte allerdings im Projekt nicht untersucht werden.



Methodik – IH-Informationen werden auf Basis einer Datenstruktur für Komponenten und Maßnahmen und mit Hilfe KI-Verfahren automatisch strukturiert

Datenstruktur für die Kategorisierung von Instandhaltungsinformationen

Für die einheitliche Strukturierung von IH-Informationen ist eine Datenstruktur für Komponenten und Maßnahmen grundlegend. Hierfür wurden relevante Regelwerke überprüft. Der Fokus lag zunächst auf Basis der rechtlichen Anforderungen an IH-Informationen von Wärmeübertragern bei Übergabestation mit indirekter Wärmeübergabe. Dabei zeigte sich, dass der Detaillierungsgrad von IH-Informationen von normativen Anforderungen (z.B. *DIN 31051 - Grundlagen der Instandhaltung*) über Verordnungen (z.B. *Verordnung über Sicherheit und Gesundheitsschutz bei der Verwendung von Arbeitsmitteln*) und technischen Regeln und Arbeitsblättern bis hin zu bauteilspezifische Herstellerdokumentation ansteigt.

Untersuchung einer Methodik für die automatisierte Annotation von Instandhaltungsinformationen

Um die IH-Informationen verwertbar zu machen, soll eine Methodik entwickelt werden, die den Freitexten automatisch eine Kategorien nach der Vorgabe einer technischen Richtlinie (wie im vorigen Kapitel beschrieben) zuweist, beispielsweise korrektive oder präventive Instandhaltung. Damit die Daten dennoch für strategische Entscheidungen genutzt werden können, wurde ein *AI-Assisted Tagging Tool* verwendet, das den Textbeschreibungen der Einsätze entsprechende Kategorien zuweist. Dafür wird eine *term-frequency-inverse-document-frequency-sortierte*-Liste aller Wörter des Textkorpuses verwendet und jedem Wort ein »Tag« zugewiesen. Diese »Tags« werden zu Kategorien aggregiert und stehen für die weiteren Analysen und für die Berechnung von strategischen Kennzahlen bereit.

Value Proposition

Value Proposition für Fernwärmebetreiber im Rahmen der Instandhaltung von Fernwärme-Hausstationen:

Optimierte Instandhaltung durch KPIs

Genauere Ausfallstatistiken basierend auf qualitativ hochwertigen KPIs sowie darauf aufbauender Analyse von Schwachstellen.

Fernfehlerdiagnose

Automatisierte Störmeldung durch KI-basierte Anomalieerkennung in Hausstationen und Fernfehlerdiagnose unter Einbeziehung der digitalisierten IH-Informationen. Dadurch können je nach Wartungsvertrag mit dem Kunden Serviceeinsätze vermieden oder Störungen schneller behoben werden.

Störungen vermeiden

Dank Verfahren der Fehlerfrüherkennung können Serviceeinsätze besser geplant und Störungen vermieden werden. Dies führt zu weniger Instandsetzungskosten und weniger Bereitschaftsdiensten der Servicetechniker.

Materialmanagement und Logistik

Langfristig kann eine prädiktive Instandhaltung zu einem verbesserten Ersatzteilmanagement und einer verbesserten Logistik führen. Perspektivisch werden Kosten gespart.

Ausblick

Die gewonnenen Erkenntnisse werden in dem Projekt »PreDist – Predictive Maintenance for District Heating« weiter entwickelt, einschließlich die Entwicklung der Klassifikatoren. Weiterhin soll die entwickelte Methodik neben der Fernwärme auf weitere Branchen ausgerollt werden, da bei vielen Assets nur semi-strukturierte Texte aus der Instandhaltung vorhanden sind und diese noch nicht vollumfänglich für strategische unternehmerische Entscheidungen genutzt werden.

Image Super Resolution und Objekterkennung in der Energiesystemanalyse

Daniel Horst, Maximilian Kleebauer

Kontakt: Daniel Horst | +49 561 7294-263 | daniel.horst@iee.fraunhofer.de

Die Objekterkennung auf Fernerkundungsbildern hat zahlreiche Perspektiven in verschiedenen Bereichen wie z. B. der Überwachung kritischer Infrastrukturen, der EE-Anlagendetektion, im Verkehr, oder im Bereich der Forstwirtschaft. Es gibt viele Methoden zur Erkennung und Lokalisierung von Objekten aus Bildern, die mit Satelliten oder Drohnen aufgenommen wurden. Für verrauschte sowie niedrig aufgelöste Bilder ist die Erkennungsleistung jedoch nicht zufriedenstellend, insbesondere bei kleinen Objekten. Ziel ist es bereits entwickelte Netzwerkarchitekturen in Verbindung mit frei verfügbaren Erdbeobachtungsdaten im Bereich der EE-Anlagendetektion zu testen und die Erkennungsgenauigkeit zu verbessern.

Auflösungsverbesserung von Sentinel-2 Daten mit Enhanced Super-Resolution Generative Adversarial Networks (ESRGAN)

Zu den üblichen Methoden zur Verbesserung der räumlichen Auflösung in der Fernerkundung gehört der Einsatz von Interpolationsfiltern oder Pan-Sharpening-Techniken bei Verfügbarkeit höher aufgelöster panchromatischer Bilder. Im Rahmen des Projektes implementieren und trainieren wir ein Modell, das auf dem Enhanced Super-Resolution Generative Adversarial Network Real-ESRGAN basiert¹. Verwendet werden dabei Bildpaare von digitalen Orthophotos (GT) und Sentinel-2-Daten (LR), um eine supraaufgelöste Sentinel-2-Ausgabe (SR) mit einem Skalierungsfaktor von 4 zu erzeugen.

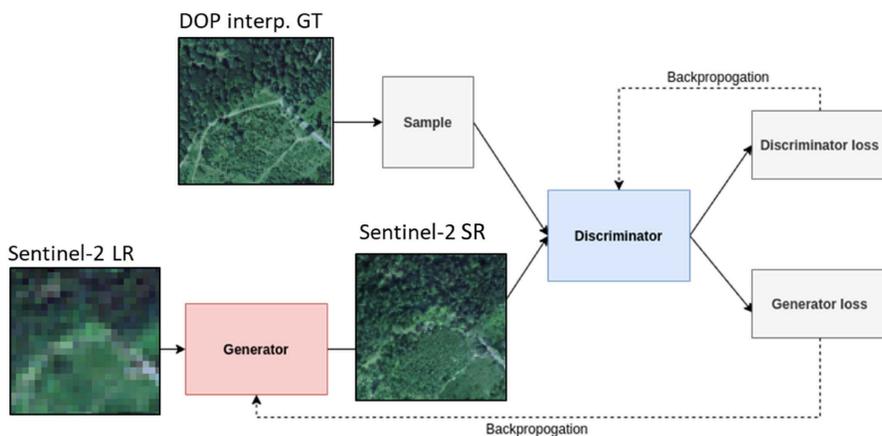


Abbildung 1: Schematische Darstellung der Real-ESRGAN Architektur mit Bildpaaren von digitalen Orthophotos und Sentinel-2-Daten. Bilddaten: © Europäische Union, enthält Copernicus Sentinel-2 Daten [2022] und GeoBasis-DE/BKG [2022]

Mit dem trainierten Real-ESRGAN-Modell wird aus Sentinel-2-Daten eine SR generiert. Die Bilder werden in verschiedene Landschaftsklassen (z.B. Wald, Siedlungsgebiet, Felder etc.) eingeteilt. Die Auswertung der SR-Bilder erfolgt zunächst optisch, da die Bildqualität der erzeugten Bilder schwierig zu messen ist. Die Ergebnisse sind beispielhaft in Abbildung 2 dargestellt. Generell besitzen die Ausgaben schärfere Konturen und Strukturen, wodurch die visuelle Repräsentation ansprechender wirkt. Erste Hyperparameter Änderungen wie Variation der Loss-Funktionen und Veränderungen der Netzwerkstiefen führten zu keiner Signifikanten Verbesserung der Ergebnisse. Für weitere Erkennungen von EE-Erzeugungsanlagen können die Ergebnisse aus dem trainierten Real-ESRGAN+ verwendet werden.



Abbildung 2: Digitale Orthophotos und Sentinel-2 Daten (links), Super Resolution Bilder für verschiedene Hyperparameter Anpassungen (rechts). (Real-ESRGAN+ entspricht den originalen Einstellungen). Bilddaten: © Europäische Union, enthält Copernicus Sentinel-2 Daten [2022] und GeoBasis-DE/BKG [2022]

Verfahren zur Detektion von erneuerbaren Energieanlagen

Das in der Arbeit entwickelte Verfahren zur Detektion von PV-Anlagen in hochauflösenden Luftbildern verzichtet auf die händische Kennzeichnung von Objekten. Durch die Kombination von Adressdaten bestehender PV-Anlagen, georeferenzierten Adressdaten sowie der Amtlichen Hausumringe Deutschlands wird eine automatisierte Erstellung von mehr als 800.000 Trainingsdaten ermöglicht. Anhand einer RetinaNet basierenden Netzarchitektur wird im Anschluss ein Netzwerk zur Objekterkennung trainiert. In einer Testanwendung unter Verwendung von digitalen Orthophotos werden Gebäude, auf denen sich PV-Anlagen befinden, mit einer hohen Genauigkeit erkannt.²

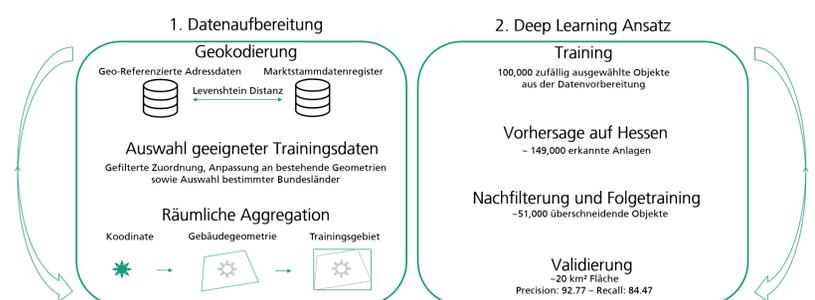


Abbildung 3: Schematische Darstellung des Verfahrens zur Detektion von erneuerbaren Energieanlagen

1. Das Generieren von Trainingsdaten ohne manuelle Selektion ermöglicht die Verwendung großer Mengen an Trainingsdaten. Allerdings können diese ungenau oder fehlerhaft sein.
2. Verschiedene Tests legen nahe, dass die Nachfilterung der Trainingsdaten die Anzahl fehlerhafter Standorte vollautomatisiert reduziert.
3. Eine mögliche Erweiterung des Verfahrens wäre eine Ausweitung der Objektklassen auf weitere EE-Anlagen.

Die Erkennung von EE-Erzeugungsanlagen in Sentinel-2 Aufnahmen mit erhöhter räumlicher Auflösung sind Gegenstand aktueller Forschungsprojekte. Ziel ist es dabei, die Kombination der dargestellten Methoden zu nutzen, um den Ausbau von EE-Erzeugungsanlagen global und mit einer hohen zeitlichen Verfügbarkeit zu bestimmen.

¹ Wang, X.; Xie, L.; Dong, C.; Shan, Y. Real-ESRGAN: Training Real-World Blind Super-Resolution with Pure Synthetic. 2021.
² Kleebauer, M.; Horst, D.; Reudenbach, C. Semi-Automatic Generation of Training Samples for Detecting Renewable Energy Plants in High-Resolution Aerial Images. Remote Sens. 2021, 13, 4793.