



LEIBNIZ UNIVERSITÄT HANNOVER
WIRTSCHAFTSWISSENSCHAFTLICHE FAKULTÄT
INSTITUT FÜR WIRTSCHAFTSINFORMATIK

Interpretierbare Vorhersagen zur photovoltaischen Energiegewinnung mit Methoden der Explainable Artificial Intelligence

MASTERARBEIT

zur Erlangung des akademischen Grades „Master of Science (M. Sc.)“ im Studiengang Wirtschaftsingenieur der
Fakultät für Elektrotechnik und Informatik, Fakultät für Maschinenbau und der Wirtschaftswissenschaftlichen
Fakultät der Leibniz Universität Hannover

vorgelegt von

Miryam Haidar Ibrahim



Prüfer:
Prof. Dr. Michael H. Breitner

Betreuer:
M. Sc. Tobias Kraschewski
M. Sc. Jana Gerlach

Hannover, den 27. Januar 2022

Inhaltsverzeichnis

Abbildungsverzeichnis	IV
Tabellenverzeichnis	VI
Formelverzeichnis	VII
Abkürzungsverzeichnis	VIII
Abstrakt und Research Summary	X
1 Einleitung	1
2 Vorhersagemodelle zur photovoltaischen Energiegewinnung	3
2.1 Relevanz von Vorhersagemodellen	3
2.2 Klassifizierung von PV-Vorhersagemodellen anhand des Prognosehorizonts	4
2.3 Modelle zur Vorhersage der photovoltaischen Energiegewinnung	5
2.3.1 Persistenzmodelle	6
2.3.2 Autoregressive-Moving-Average-Model	7
2.3.3 Support-Vector-Machine	8
2.3.4 Hybridmodelle	10
2.4 Künstliche neuronale Netze	11
2.4.1 Allgemeine Funktionsweise	12
2.4.2 Einfaches Perzeptron	13
2.4.3 Mehrschichtige neuronale Netze	14
2.5 Training und Lernverfahren	17
2.5.1 Trainings- und Lernprozess	17
2.5.2 Bewertung von Trainingsmethoden mit Fehlerfunktionen	20
2.5.3 Gradientenabstiegsverfahren	21
2.5.4 Backpropagation-Algorithmus	23
2.5.5 Adam-Verfahren	24
2.6 Anpassungsgrad des Modells	24
2.6.1 Über- und Unteranpassung	25
2.6.2 Early Stopping zur Vermeidung der Überanpassung	27
2.7 Explainable Artificial Intelligence	28

2.7.1	Definition und Relevanz der XAI	28
2.7.2	Ziele der XAI	30
2.7.3	Methoden zur Visualisierung, Interpretation und Erklärung von KNN	31
2.8	Vergleich von Studien auf der Grundlage von Techniken, Genauigkeit und XAI-Modellen	34
3	Modellbeschreibung und Datenaufbereitung	36
3.1	Methodik und Modellauswahl	36
3.2	Datenauswahl	38
3.2.1	Outputdaten für das PV-Vorhersagemodell	38
3.2.2	Auswahl der Inputdaten für das PV-Vorhersagemodell	39
3.3	Vorverarbeitung der Modelldaten	41
3.3.1	Fehlerbehebung und Anpassung der zeitlichen Auflösung der Datensätze	41
3.3.2	Normierung der Datensätze	45
4	Entwicklung und Interpretation des Vorhersagemodells zur photovoltaischen Energiegewinnung	46
4.1	Implementierung des Modells	46
4.2	Training und Validierung	50
4.3	Optimierung der Performance	54
4.3.1	Auswahl der Modellparameter	54
4.3.2	Anwendung von Regulierungsmethoden	60
4.4	Interpretation des Modells durch XAI-Methoden	62
4.4.1	Interpretation anhand der SHAP-Methode	63
4.4.2	Interpretation anhand der LIME-Methode	68
5	Analyse und Diskussion der Ergebnisse	70
5.1	Prognosen und Ergebnisse	70
5.2	Diskussion der Ergebnisse	73
5.2.1	Erzielte Performance des Modells	74
5.2.2	Beobachtungen und Vergleich zu anderen Studien bezüglich der Interpretation des Modells	77
5.3	Limitationen und Schwächen des Modells	79
5.4	Implikationen und Handlungsempfehlungen	80

6 Zusammenfassung und Ausblick	82
Literatur	83
A Anhang	90
A.1 Weitere Interpretationsvisualisierungen	90
A.2 Implementierung des Modells und der XAI-Methoden	91
Ehrenwörtliche Erklärung	96

1 Einleitung

Aufgrund der weltweiten Zunahme des Energieverbrauchs, kam es in der Vergangenheit zu einer globalen Besorgnis über den zukünftigen, wachsenden Energiebedarf. Um diesen zu decken, erfolgte eine Umstellung auf nachhaltigere Energiequellen (Kuzlu et al., 2020). Hierbei hat sich die Photovoltaik (PV) weltweit durchgesetzt und spielt deshalb heutzutage eine wichtige Rolle bei der Bereitstellung sauberer und nachhaltiger Energie. Daher hat die Installation von PV-Anlagen alleine in den letzten vier Jahren ein großes Wachstum erfahren (U. K. Das et al., 2018). Alleine in Deutschland wurden im Jahre 2020 etwa 184000 PV-Anlagen registriert. Die Bruttostromerzeugung der PV betrug 2018 45800 GWh und stieg bis auf 51000 GWh im Jahre 2020 an (Bundesverband Solarwirtschaft (BSW), 2021).

Die Erzeugung von PV-Strom hängt jedoch vollständig von unsicheren und unkontrollierbaren meteorologischen Faktoren ab. Dazu gehören beispielsweise die Sonneneinstrahlung, Lufttemperatur, Windrichtung oder die Feuchtigkeit. Die Leistungsabgabe einer PV-Anlage ändert sich dynamisch mit der Zeit aufgrund der Variabilität der Umweltfaktoren. Aus diesem Grund ist eine genaue Vorhersage der PV-Stromerzeugung schwierig. Die nicht prognostizierbare PV-Leistung beeinträchtigt neben dem wirtschaftlichen Nutzen auch die Stabilität, die Zuverlässigkeit und die Planung des Stromnetzbetriebs (Strzalka et al., 2012). Eine genaue Vorhersage könnte die Auswirkungen der Unsicherheiten bei der PV-Stromerzeugung auf das Netz verringern, die Systemzuverlässigkeit verbessern, die Stromqualität aufrechterhalten und den Verbreitungsgrad der PV-Systeme erhöhen (U. K. Das et al., 2018).

Daher spielt die genaue Vorhersage der PV-Stromerzeugung eine entscheidende Rolle. Um die Probleme des modernen Stromnetzes anzugehen und dessen Effizienz und Zuverlässigkeit zu erhöhen, ist der Einsatz von Methoden der künstlichen Intelligenz (KI) notwendig. Entsprechende KI-Methoden spielen eine entscheidende Rolle bei der Entwicklung zu einem intelligenten Netz (Kuzlu et al., 2020). Dennoch wird KI immer noch als Black-Box-Methode betrachtet, da die Funktionsweise der grundlegenden Modelle nicht einfach zu verstehen ist. Dies hat zur Folge, dass Akteure der Energiewirtschaft zögern, KI-basierte Techniken einzusetzen, da Erklärungs- und Interpretationsmöglichkeiten fehlen.

Mit der Explainable Artificial Intelligence (XAI) wird diesem Problem begegnet, indem

damit die Erklärbarkeit und Transparenz der KI-Modelle erhöht werden und dadurch ein Black-Box-Modell erklärt und interpretiert wird. Aufgrund der genannten Aspekte und Herausforderungen, die die Grundlage für die Motivation und Zielsetzung dieser Arbeit bilden, ist das Ziel, sich auf die Vorhersage von PV-Anlagen unter Verwendung von XAI-Methoden zu konzentrieren. Ein Grund für deren Betrachtung ist die geringe Anzahl an Studien, in denen die XAI für Energieprognosen untersucht wurde.

Zu Beginn erfolgt in Kapitel 2 ein Überblick über die theoretischen Grundlagen zu Vorhersagemodellen der photovoltaischen Energiegewinnung. Hierbei werden grundlegende Modelle vorgestellt und es wird auf ihre allgemeine Funktionsweise eingegangen. Ein Fokus wird in diesem Zusammenhang auf die künstlichen neuronalen Netze (KNN) und deren Training gelegt. Außerdem erfolgt in diesem Kapitel die Erläuterung der XAI-Ansätze. Anschließend erfolgen in Kapitel 3 die Auswahl und Aufbereitung der Daten für das zu erstellende Modell. In Kapitel 4 werden die Entwicklung, das Training, die Optimierung und Interpretation des Vorhersagemodells beschrieben. Abschließend werden in Kapitel 5 die Ergebnisse der Arbeit analysiert und diskutiert mit einer darauf folgenden Betrachtung der Limitationen und der Handlungsempfehlung. In Kapitel 6 werden die Ergebnisse der Arbeit mit einem Ausblick zusammengefasst.

6 Zusammenfassung und Ausblick

In dieser Arbeit wurde die Anwendung eines KNN zur Vorhersage der PV-Stromerzeugung vorgestellt. Darüber hinaus werden XAI-Methoden wie SHAP und LIME auf das KNN-Modell angewandt, um die Gründe für eine bestimmte Vorhersage zu verstehen und zu erklären. Zudem dient diese Arbeit dazu, die Bedeutung der Einführung von XAI-Methoden in PV-Vorhersage-Anwendungen zu erläutern. Die Motivation dieser Themen bildet die aktuelle Relevanz der Vorhersagemodelle und der XAI-Methoden bezüglich photovoltaischer Energiegewinnung. Die für diese Arbeit verwendeten Daten sind öffentliche Datensätze vom DWD und OPSD. Die Umsetzung der Implementierung erfolgte mithilfe der Programmiersprache Python und der auf TensorFlow basierenden Programmiersprache Keras. Nach der Auswahl der optimalen Hyperparameter des Modells wurde mithilfe von Regulierungsmethoden versucht ein optimales Ergebnis bezüglich des RMSE und MAPE zu erzeugen. Diese Ergebnisse wurden anschließend mit den XAI-Methoden SHAP und LIME interpretiert. Auf Grundlage dessen konnten im Anschluss die Prognosen und Ergebnisse analysiert und diskutiert werden.

Insgesamt lässt sich schließen, dass das Ziel dieser Arbeit mit einem guten Ergebnis des $RMSE = 5,54 \%$ erreicht wurde, sodass klargelegt wird, dass ML-Techniken wie KNN gut für PV-Vorhersagen geeignet sind. Es ist zu erwähnen, dass bezüglich des MAPE mit etwa $20,41 \%$ dieser Arbeit leicht schwächere Ergebnisse als in anderen Studien erzielt werden. Den Ergebnissen der Interpretation zufolge können XAI-Methoden detaillierte Informationen zur Interpretation der Inputmerkmale und -ergebnisse des Modells liefern. Es wurde außerdem aufgezeigt, dass jede XAI-Methode ihre eigenen Stärken und Grenzen hat, was die Rechenkosten und die lokale und globale Erklärung betrifft.

Für die Erweiterung dieser Arbeit empfiehlt sich im Allgemeinen die Anwendung anderer Modelle, beispielsweise eines RBFN oder Hybridmodelle, und objektiv zu betrachten, ob hierdurch eine bessere Performance erreicht und die Anwendung der XAI-Modelle erleichtert wird. Durch Visualisierungsmethoden, die Technologien wie KI unterstützen, bieten XAI-basierte PV-Solarprognosesysteme eine produktive Erweiterung für Energieversorger. Der Einsatz möglicher ML-Techniken wird dadurch ermöglicht, ohne dass große Erfahrungen in diesem Bereich von Mitarbeitenden eines Unternehmens benötigt werden. Diese Arbeit soll Forschern, die sich mit Stromerzeugungs- und Lastprognosen befassen, aufzeigen, welches Potenzial die Verfügbarkeit von KI-Methoden in Kombination mit XAI hat.