

Herausgeber Prof. Dr. Barbara Dörsam

Schriftreihe Bachelor-Resümee

Forschungsbereich **Künstliche Intelligenz**

Prognoseerstellung mit neuronalen Netzen

Vorhersagen von Solarenergieerträgen anhand von Wettervorhersagen

Luca Maurice Gölz

Studieren. Wissen. Machen.

Impressum

Hochschule der Medien

Nobelstrasse 10

70569 Stuttgart

www.hdm-stuttgart.de

0711 8923-0

Autor

Luca Maurice Gölz

Betreuer

Prof. Dr. Barbara Dörsam

Datum

Februar 2024

Wirtschaftsingenieurwesen Medien

www.hdm-stuttgart.de/wing

hitzges@hdm-stuttgart.de

0711/8923-2634

Layout

Jochen Riegg

Fotos und Illustrationen

Innenteil: Luca Maurice Gölz

Bachelor-Resümee

Prognoseerstellung mit neuronalen Netzen

Vorhersagen von Solarenergieerträgen anhand von Wettervorhersagen

Luca Maurice Gölz

Februar 2024

Der Autor

Luca Maurice Gölz erlangte seine allgemeine Hochschulreife 2019. 2020 begann er sein Studium „Wirtschaftsingenieurwesen Medien“ an der Hochschule der Medien in Stuttgart mit Schwerpunkt auf digitale Technologien. Diese vertiefte er unter anderem bei Hochschulprojekten oder Arbeitnehmertätigkeiten bei Bosch Rexroth, der Mercedes Benz Group oder dem Fraunhofer Institut.

Inhaltsverzeichnis

1. Einleitung.....	5
1.1. Vorhaben.....	5
1.2. Neuronale Netze	5
2. Umsetzung.....	6
2.1. Ausgangslage.....	6
2.2. Datenaufbereitung.....	6
2.3. Erstellen und Trainieren des neuronalen Netzes.....	7
2.4. Evaluation der Testprognose	8
3. Anwenden der finalen Modelle.....	9
4. Fazit	11
5. Literaturverzeichnis.....	12

1. Einleitung

1.1. Vorhaben

Die Folgen des Klimawandels machen sich immer stärker bemerkbar. Hauptverursacher dieser Entwicklung ist die Menschheit [1]. Ob in Politik, Wirtschaft oder dem alltäglichen Leben – die Notwendigkeit von Nachhaltigkeit wird immer deutlicher. In einer Umfrage von Wegatech, einem deutschen Unternehmen für Energietechnologien, veröffentlicht im August 2022, wurden Eigenheimbesitzer im Alter von 25-65 Jahren befragt, wie wichtig Ihnen eine autarke Energieversorgung sei. 81% der Befragten gaben an, dass Thema sei Ihnen sehr wichtig [2]. Energieautarke Gebäude decken den gesamten oder zumindest einen Teil ihres benötigten Stroms eigenständig ab. Meist sind Photovoltaikanlagen auf dem Dach angebracht, welche mithilfe von Solarzellen die Strahlen der Sonne einfangen und in elektrische Energie umwandeln. Diese kann dann als Energiequelle für den eigenen Bedarf verwendet werden.

Zehn Studierende des Studiengangs Wirtschaftsingenieurwesen Medien der Hochschule der Medien in Stuttgart haben dazu eine intelligente Anwendung entwickelt, die einen Haushalt simuliert und an diesem Beispiel zeigt, wie das eigene Zuhause autark gestaltet werden kann. Immanuel Ricker legte im Sommersemester 2023 dar, dass es eine Korrelation zwischen der Wettervorhersage und den Erträgen solcher Photovoltaikanlagen gibt. Er nutzte sog. „ARMA-Modelle“, um diese Erträge vorhersagen zu können. Ziel dieser Arbeit ist es, statt der Verwendung statistischer Modelle die Prognostizierbarkeit dieser Solarenergieerträge mithilfe von künstlichen neuronalen Netzen zu erforschen.

Solche Modelle zur Prognose von Solarenergieerträgen existieren bereits. Das Fraunhofer-Institut hat im Zeitraum von 2014-2018 ein Projekt namens „ANNSolar“ geführt. Hierbei wurden neuronale Netze eingesetzt, um Prozesse von Solarthermieanlagen zu beobachten und mit den Ergebnissen Einblicke in potenzielle Verbesserungen des Energieverbrauchs zu erlangen. In 80 % der Fälle lag der relative Fehler der Vorhersage von den Solarenergieerträgen bei oder unter 15,2 % [3]. Die Art und Weise der Umsetzung dieser Modelle ist jedoch nicht explizit bekannt. Der Erfolg eines solchen Modells ist von vielen verschiedenen Faktoren abhängig. Diese Arbeit erforscht die Entwicklung und Leistungsfähigkeit eines solchen Modells an einem privaten Haushalt im Raum Stuttgart mit zwei Photovoltaikanlagen.

1.2. Neuronale Netze

Neuronale Netze bestehen aus zusammengeschalteten Neuronen, mehreren „Zellen“. Jedes einzelne dieser Neuronen repräsentiert eine Funktion, die aus einer Anzahl x -Variablen eine y -Variable erzeugen kann. Im Fall der neuronalen Netze spricht man hier von „Input“ und „Output“. Für jeder der Eingangsmerkmale bestimmt das Neuron Gewichtungskoeffizienten w_i . Ein Neuron berechnet die Summe aller Produkte der Eingangsmerkmale x_i mit deren Gewichtungskoeffizienten w_i und addiert letztendlich noch den „Bias“ b , welcher einen allgemeinen Wert darstellt und die Summe der vorherigen Addition noch beeinflussen kann. Dies ist in Abb. 1 graphisch dargestellt.




Abbildung 1 Funktionsweise eines Neurons

Für diese Arbeit wird mit einem rekurrenten neuronalen Netz mit LSTM-Knoten gearbeitet. Ein rekurrentes neuronales Netz arbeitet mit Zeitfenstern. Ein Neuron berechnet einen Schätzwert y_{pred} , welcher dann in die Berechnung des Schätzwertes y_{pred} des nächsten Zeitfensters miteinbezogen wird. Durch diesen sequenziellen Ablauf ist der Verlauf aller Variablen, darunter Eingangsmerkmale x_i und Gewichtungskoeffizienten w_i , gut erkennbar und das neuronale Netz kann all seine vorherigen Erfahrungswerte in die Berechnung neuer Werte einfließen lassen. Um die Funktionalität dieses Langzeitgedächtnisses bei großen Datensätzen garantieren zu können, werden LSTM-Knoten innerhalb der Schichten des neuronalen Netzes verwendet. Knoten sind ein Synonym für die Art der Neuronen innerhalb der neuronalen Schichten eines Netzes. Vorteil dieser Knoten ist deren Fähigkeit sowohl als Kurzzeit- als auch als Langzeitgedächtnis zu dienen. Innerhalb der Knoten gibt es Instanzen, sog. „Gates“, welche bestimmen, ob die aktuell durchlaufenden Informationen von Bedeutung sind oder nicht. Mithilfe mathematischer Operationen können unwichtige Informationen vergessen werden, wohingegen die wichtigen Informationen langfristig gespeichert und weitergegeben werden.

2. Umsetzung

2.1. Ausgangslage

Die zu prognostizierenden Leistungserträge basieren auf den Daten zweier Photovoltaikanlagen eines privaten Haushalts im Raum Stuttgart. Die erste Photovoltaikanlage (PV1) ist in Ost-West-Richtung ausgerichtet und seit 2013 in Betrieb. Die zweite Photovoltaikanlage (PV2) ist in Süd-Richtung ausgerichtet und seit 2017 in Betrieb. Die Wetterdaten sind mithilfe einer API von openweathermap.org zusammengestellt worden.

Die Photovoltaik-Anlagen sind unterschiedlich lange in Betrieb und unterschiedlich ausgerichtet. Dies garantiert unterschiedliche Leistungswerte, weshalb die Entwicklung eines einzigen neuronalen Netzes für beide Anlagen unnützlich gewesen wäre. Aufgrund dessen wird im Laufe dieser Arbeit für beide Photovoltaik-Anlagen jeweils ein eigenes neuronales Netz mit denselben Parametern kreiert.

2.2. Datenaufbereitung

Zunächst werden die Solardaten tabellarisch aufbereitet und deren Verlauf über den verfügbaren Zeitraum grafisch dargestellt. Darauf werden mithilfe eines Skripts die relevanten Daten aus den

Wetterdaten herausgearbeitet und ebenfalls tabellarisch aufgelistet. Diese Datensätze werden dann konsolidiert. Der finale Datensatz einer Photovoltaik-Anlage vereint nun dessen Leistungswerte und die für diesen Zeitraum relevanten Wettervorhersagedaten. Die in der Bachelorarbeit von Immanuel Ricker herausgefilterten für die Photovoltaik-Anlagen relevanten Werte der Wettervorhersage sind Temperatur, Druck, Wolken, Luftfeuchtigkeit, Wolken und Windgeschwindigkeit.

Das neuronale Netz muss nach dem abgeschlossenen Training evaluiert werden, dies kann nur mit unbekanntem Daten erfolgen, da es sonst die resultierenden Energieerträge bereits kennen würde. Aufgrund dessen werden die konsolidierten Datensätze in Test- und Trainingsdaten unterteilt. Beide Datensätze müssen dabei groß genug sein, um repräsentative Trainings- und Evaluierungsprozesse garantieren zu können. Außerdem wird die Zielvariable „Leistung“ in externe Datensätze extrahiert, da diese nicht als Eingangsmerkmal dem neuronalen Netz zur Verfügung gestellt werden darf. Daraufhin müssen alle Datensätze, sowohl die des Inputs als auch die des Outputs, skaliert werden. Die Notwendigkeit von einheitlichen Messskalen der Merkmale liegt an dem sogenannten „Backpropagations-Mechanismus“ des neuronalen Netzes. Dieser beschreibt den Prozess der Anpassung der Gewichtungskoeffizienten mittels mathematischer Operationen und einer Verlustfunktion während des Trainingsprozesses.

Zuletzt werden die Trainings- und Testdatensätze in die für rekurrente neuronale Netze essenziellen Zeitfenster unterteilt und deren Struktur in zwei- und dreidimensionale Arrays angepasst.

2.3. Erstellen und Trainieren des neuronalen Netzes

Nun werden die einzelnen Parameter des neuronalen Netzes bestimmt. Die sogenannten ‚Units‘ bestimmen die Anzahl der Neuronen im Netz. Die Anzahl der Schichten, in denen diese Neuronen liegen, werden als ‚Layer‘ bezeichnet. Für das Training des neuronalen Netzes mussten noch die Anzahl der ‚Epochen‘ bestimmt werden. Diese geben vor, wie viele Trainingsdurchläufe das Modell mit den Daten machen soll, um die Fehlerquote zu verringern. Der letzte Parameter ist ‚Batch Size‘. Dieser gibt an, wie viele Trainingswerte in einem einzigen Backpropagations- und Forwardpropagations-Mechanismus verwendet werden sollen. Die Forwardpropagation ist der Gegenspieler der Backpropagation und reicht die Daten durch die verschiedenen Layer hindurch bis zum Ende. Dort beginnt dann die Backpropagation. Für die Wahl der Werte dieser Parameter gibt es keine Regeln. Die Gegebenheiten und die Aufgabe jedes neuronalen Netzes sind unterschiedlich. Aufgrund dessen müssen die Parameter über Ausprobieren getestet werden und nach Evaluation der Ergebnisse angepasst werden.

Das Kreieren des Modells und alle damit verbundenen Operationen werden mithilfe der Keras-API gemacht. Die Keras-API ist ein Teil des Tensorflow-Frameworks. Es wird ein sequenzielles Modell angelegt, ein rekurrentes neuronales Netz. Jedem Layer wird die Anzahl an festgelegten Units zugeordnet, in diesem Fall LSTM-Neuronen. Jede dieser Schichten erhält eine Eingabe mit der Struktur (Zeitschritte, Anzahl der Merkmale). Diese Schichten sind instruiert Sequenzen zurückzugeben, da hier mehrere LSTM-Schichten hintereinandergeschaltet sind und diese jeweils eine Sequenz als Eingabe erwarten. Die letzte dieser Schichten, die zusätzlich nach der Schleife hinzugefügt wurde, erhält die Schätzwerte der vorherigen Schicht und erwartet bei der Eingabe nur ein Merkmal pro Zeitfenster. Die sogenannte „Dense-Schicht“ erzeugt dann die finale Ausgabe des Modells. Zuletzt werden noch die Verlustfunktion und der Optimierer ausgewählt. Der Optimierer ist für die Berechnung der potenziellen Gewichtsadjustierungen zuständig.

Während des Trainingsprozesses werden verschiedene Fehlerwerte ausgegeben, mit denen das Training bewertet werden kann. Dabei verhindern integrierte Callback-Funktionen, dass der Verlauf dieser Fehlerwerte für eine bestimmte Anzahl an Epochen keine ungewünschten Ausmaße annehmen. Der Verlauf der wichtigsten Fehlergröße während des Trainings ist in Abb. 2 zu sehen.




Abbildung 2 Entwicklung des Fehlers während des Trainings des Modells der PV1

2.4. Evaluation der Testprognose

Das trainierte Modell kann nun eine Prognose für die Testdaten erstellen, welche mit den realen Werten verglichen wird. Aus den daraus gewonnenen Erkenntnissen lassen sich potenzielle Verbesserungsmöglichkeiten identifizieren und die vorherigen Schritte werden dementsprechend angepasst. Dieser Prozess sollte wiederholt werden, bis das Ergebnis der Testprognose zufriedenstellend ist. Das Anpassen der vorherigen Schritte beinhaltet nicht nur die Variablen des neuronalen Netzes. Jeder Schritt von der Datenaufbereitung bis zum Trainieren des Modells muss in Frage gestellt werden.

In dieser Arbeit wurde zunächst die Fehlerfunktion des Modells ausgetauscht. Der „Mean Squared Error“ hat aufgrund seiner mathematischen Operationen so hohe Werte produziert, dass diese sowohl für den Evaluierungsprozess als auch für den Optimierer des neuronalen Netzes ungeeignet waren. Die Fehlerwerte konnten nicht aussagekräftig interpretiert werden und der Optimierer konnte während des Trainings die entstandenen Fehlerwerte nicht kontextgemäß einordnen, so dass das Anpassen der Gewichtungskoeffizienten der Eingangsmerkmale ineffizient war. Der „Mean Absolute Error“ hat dabei deutlich besser interpretierbare Werte für sowohl die Evaluation der Testprognose als auch für die Gewichtungsanpassung während des Trainingsprozesses geliefert.

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j|$$

Darüber hinaus hatte das Modell Probleme damit, die unterschiedlichen Gegebenheiten von Tag, Nacht und Jahreszeit zu verstehen. Dafür wurden den Datensätzen neue, one-hot-codierte Eingangsmerkmale hinzugefügt, welche Informationen über Uhrzeit, Tageszeit und Jahreszeit liefern. Ein Ausschnitt der finalen Datensätze ist in Abb. 3 zu erkennen.

Datum	Leistung	temp	pressure	humidity	clouds	windSpeed	time	daytime	nighttime	season
2019-08-08 09:00:00	57984.0	295.586	1014.89	57	18	2.52	9	1	1	3
2019-08-08 12:00:00	85416.0	297.808	1014.38	47	43	3.23	12	1	1	3
2019-08-08 15:00:00	46416.0	298.065	1013.66	46	94	3.02	15	1	1	3

Abbildung 3 Ausschnitt des konsolidierten Datensatzes

Neben diesen Anpassungsmöglichkeiten wurden auch weitere Maßnahmen näher erläutert. Diese sind im Gegensatz zum Anpassen der Parameter des neuronalen Netzes oder dem Hinzufügen neuer Eingangsmerkmale deutlich aufwendiger. Neben den Parametern kann auch die allgemeine Struktur des neuronalen Netzes angepasst werden. Die automatisch erstellten Lernraten für die Merkmale während des Trainingsprozesses könnten manuell bestimmt werden. In der Fehlerfunktion könnten eigene Gewichtungen für die Eingangsmerkmale festgelegt werden. Die Verkleinerung der Zeitfenster für die rekurrenten neuronalen Schichten könnte ebenfalls sinnvoll sein. Diese und viele weiteren Maßnahmen werden in der Arbeit näher beschrieben und bewertet.

3. Anwenden der finalen Modelle

Nach abgeschlossener Evaluierung haben beide Modelle eine Prognose der Solarenergieerträge der Photovoltaikanlagen für den Zeitraum von Oktober 2023 bis Mitte Dezember 2023 erstellt, welche dann mit den realen Werten verglichen wurden. Diese sind in Abb. 4 und 5 zu sehen. Der durchschnittliche absolute Fehler beider Modelle lag dabei bei ungefähr 4500 und 6000 Einheiten. Gründe für die unterschiedlichen Werte der Modelle trotz exakt gleichen Aufbaus könnte unter anderem an einer erhöhten Anzahl ungewöhnlicher Werte in den Trainingsdaten und somit einem unterschiedlich erfolgreichen Training oder an der unterschiedlichen geographischen Ausrichtung der Photovoltaikanlagen liegen. Die unterschiedliche Ausrichtung der Anlagen garantiert eine ungleiche Erfahrung der Wetterfaktoren.

Prognoseerstellung mit neuronalen Netzen




Abbildung 4 Prognose des PV1-Modells für 01.10.2023 - 16.12.2023

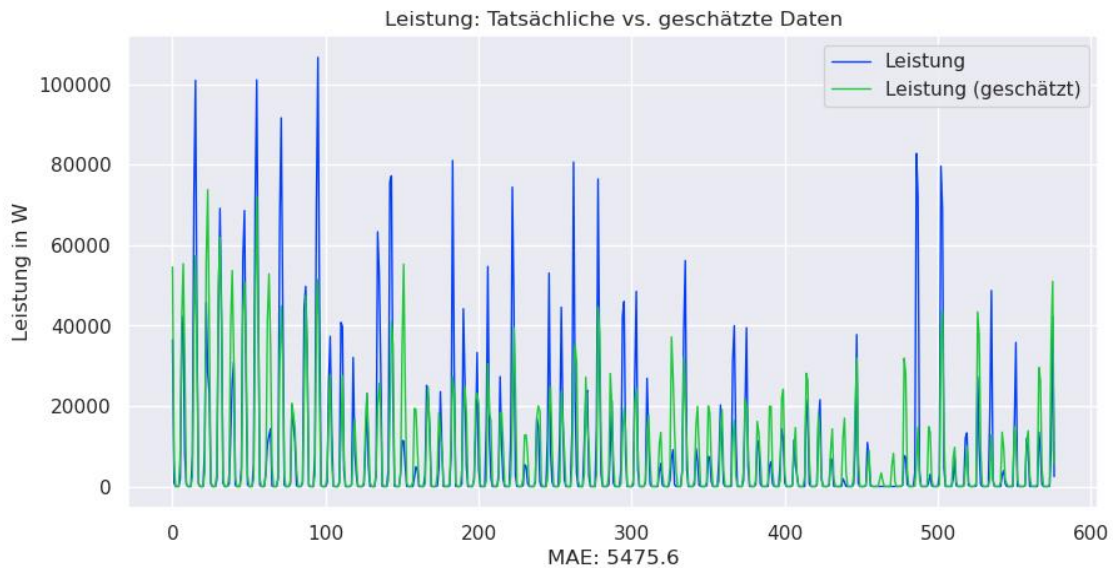


Abbildung 5 Prognose des PV2-Modells für 01.10.2023 - 16.12.2023

Beide Prognosen weisen starke Unterschiede im ersten Drittel der Vorhersage auf. Dieser Zeitraum ist der Oktober 2023, welcher sowohl der regenreichste Oktober seit 2002 in Deutschland als auch der drittwärmste Oktober in Baden-Württemberg seit 1881 war [4]. Ungewöhnliche Wetterfaktoren sind unabdingbar, diese sind auch bei der Testvorhersage zu erkennen, welche einen Zeitraum von über einem Jahr abdeckt. Mit einem Blick auf die absoluten einzelnen Werte der Vorhersagen war zu erkennen, dass die Modelle die größten Vorhersagdifferenzen um 15:00 Uhr und 18:00 Uhr vorweisen. Der Nachmittag und frühe Abend sind also für die Modelle am schwersten vorherzusagen.

4. Fazit

Eine Prognose der Leistungswerte von PV-Anlagen anhand von Wettervorhersagen mithilfe neuronaler Netze ist definitiv möglich. Durch die Implementierung von LSTM-Knoten konnte die gesamte Zeitreihe in ein Langzeitgedächtnis eingepflegt werden. Es gab keinen Zeitpunkt im Laufe der Arbeit an dem es eine Anforderung zu bewältigen gab, auf welche die Technologie der neuronalen Netze keine Antwortmöglichkeiten geboten hat. Das Modell und all seine Teilbereiche müssen stetig evaluiert und angepasst werden. Nur so lassen sich die optimalen Voraussetzungen für ein bestmögliches Ergebnis bestimmen. Aufgrund dessen können die Modelle nahezu nie abgeschlossen und in ihrer Leistungsfähigkeit ausgereizt sein.

In den Vorhersagen aus Kap. 4 ist zu erkennen, dass die Modelle zu gewissen Zeitpunkten keine sehr genauen Ergebnisse liefern. Doch für den Anwendungsfall im Kontext der Energieplanung müssen sie das auch nicht. Private Haushalte benötigen nicht den genauen Wert der wahrscheinlich erzeugten Energie, sondern nur eine grobe Aussicht. Darüber hinaus sind die Zeitfenster der Modelle sehr groß, weshalb sehr genaue Vorhersagen schwer möglich sind. Für die Anwendung in einem Privathaushalt, um zu bestimmen, ob die PV-Anlagen ausreichen werden, um in einem bestimmten Zeitfenster den Stromverbrauch ausgewählter Geräte abzudecken, sind die Modelle definitiv anwendungstauglich. Darüber hinaus würden die Modelle bei längerer Benutzung und stetiger Einpflegung der Daten immer leistungsfähiger werden. Zusammenfassend lässt sich sagen, dass die Vorhersage von Solarenergieerträgen anhand von Wettervorhersagen mit neuronalen Netzen möglich ist und die Arbeit somit erfolgreich war. Die Modelle sind präzise genug, um die Anwendung in einem privaten Haushalt zur Energieplanung zu verwenden.

5. Literaturverzeichnis

- [1] B. Deutschland, 16 Februar 2023. [Online]. Available: <https://www.bundesregierung.de/breg-de/schwerpunkte/umgang-mit-desinformation/faktencheck-klimakrise-1936176>.
- [2] Wegatech, „Wie wichtig ist Ihnen das Thema autarke (unabhängige) Energieversorgung?“, 2022.
- [3] F. ISE, „Künstliche Neuronale Netzwerke für die Anwendung in der Solarthermie.“ Freiburg, 2019.
- [4] „DWD,“ 30 Oktober 2023. [Online]. Available: www.dwd.de/DE/presse/pressemitteilungen/DE/2023/20231030_deutschlandwetter_oktober2023_news.html.