

Vorhersage der Solarstrahlung am Boden mittels Satellitenbeobachtungen und maschinellen Lernverfahren

Clemens Seeger¹, Fabian Schruppf¹, Jonas Witthuhn², Hartwig Deneke², Mirco Fuchs¹

¹ Laboratory for Biosignal Processing, Hochschule für Technik, Wirtschaft und Kultur Leipzig, Eilenburger Str. 13, 04317 Leipzig

² Leibniz-Institut für Troposphärenforschung, Permoserstraße 15, 04318 Leipzig

Abstract

Zur Vorhersage der globalen Solarstrahlung am Erdboden (GSR) wird eine Deep-Learning-basierte Methode vorgestellt, die neben Satellitenaufnahmen auch Informationen nahegelegener Bodenmessstationen sowie zugehörige Metadaten nutzt. Dabei wird der Einfluss der nahegelegenen Messstationen auf das Vorhersageergebnis systematisch untersucht. Zum Trainieren und Evaluieren des Netzwerkes werden Satellitenaufnahmen Deutschlands sowie GSR-Messungen von 113 Wetterstationen des Deutschen Wetterdienstes von 2015 verwendet. Das Netzwerk besteht aus einem VGG-16-Netzwerk mit bereits erlernten Gewichten und einem darauffolgendem Dense Neural Network welches lernt, ausgehend von den erkannten Merkmalen in den Satellitenaufnahmen und Metadaten sowie zusätzlichen Informationen nahegelegener Messstationen, die kumulierte Globalstrahlung der nächsten Stunde vorherzusagen. Das Netzwerk erzielt eine hohe Vorhersagegenauigkeit der GSR und erreicht auf dem Testdatensatz ab einer Anzahl von 5 einbezogenen nahegelegenen Messstationen einen mittleren quadratischen Fehler (RMSE) von $77,24 \text{ W/m}^2$. Die Ergebnisse zeigen den Nutzen der zusätzlichen Informationen nahegelegener Messstationen und deuten darauf hin, dass die vorgestellte Methode verwendet werden kann, um die GSR auch an bisher nicht gemessenen Orten mit hoher Genauigkeit vorherzusagen.

Keywords: Solarstrahlung, Satellitenaufnahmen, Deep Learning, Neuronales Netzwerk

1. Einleitung

Im Rahmen der Energiewende spielen Photovoltaikanlagen (PV-Anlagen) eine zunehmend wichtigere Bedeutung. Die wichtigste Einflussgröße für die Planung und für den Betrieb dieser Anlagen ist die Globalstrahlung (Global Solar Radiation – GSR). Diese beschreibt die nutzbare solare Strahlungsenergie auf der Erdoberfläche. Eine genaue Vorhersage der GSR ist für ein effizientes Energiemanagement und Prognosen zur Energiegewinnung von entscheidender Bedeutung.

Gegenstand dieser Arbeit ist eine Deep-Learning-basierte Methode, um die Globalstrahlung am Erdboden vorherzusagen. Der vorgeschlagene Algorithmus verwendet

neben Satellitenaufnahmen auch Informationen über Messwerte nahegelegener Bodenmessstationen sowie zugehörige Metadaten (geografische Lage, Messzeitpunkte) zur Vorhersage der kumulierten GSR-Strahlung der nächsten Stunde. Es soll der Einfluss der nahegelegenen Messstationen auf das Vorhersageergebnis systematisch untersucht werden.

2. Methoden

2.1 Daten

Im Zentrum dieser Arbeit steht die Prädiktion der GSR-Strahlung unter Verwendung von Satellitenaufnahmen und zusätzlicher Daten nahegelegener Referenzstationen. Für Erstere wurden Daten der Europäischen Organisation für meteorologische Satelliten (EUMETSAT) verwendet [1]. Sie umfassen Satellitenaufnahmen Deutschlands des geostationären Meteosat-10 Satelliten aus dem Jahr 2015 in unterschiedlichen Wellenlängenbereichen. Für diese Arbeit wurden Aufnahmen im sichtbaren Wellenlängenbereich (600 nm - 900 nm) verwendet. Die Bildauflösung beträgt 720x1200 Pixel, mit einer Ortsauflösung in Deutschland von ca. 2x1 km/Pixel [2]. Die GSR-Messungen der Bodenstationen wurden einer öffentlich zugänglichen Datenbank des Deutschen Wetterdienstes (DWD) entnommen [3]. Sie beinhalten stündlich kumulierte Messungen der am Boden auftretenden Globalstrahlung von insgesamt 113 Wetterstationen in Deutschland aus dem Jahr 2015.

2.2 Datenvorverarbeitung

Zunächst erfolgte eine Aufteilung der Daten entsprechend ihrer Stationszugehörigkeit so, dass 23 Stationen als Teststationen und die Daten der übrigen 90 Stationen für das Training des Verfahrens separiert wurden. Auf diese Weise wurde ein vom Trainingsdatensatz unabhängiger Testdatensatz zur realistischen Einschätzung der Vorhersagegenauigkeit geschaffen. Bei der Auswahl der Teststationen wurde auf eine gleichmäßige räumliche Verteilung über ganz Deutschland geachtet. In Abbildung 1 ist diese Unterteilung dargestellt. Die Daten der übrigen 90 Trainingsstationen wurden im Verhältnis 80%/20% zufällig einem Trainings- und einem Validierungsdatensatz zugeordnet. Für jeden Messwert des Datensatzes wurde aus der dazugehörigen Satellitenaufnahme (zeitliche Korrespondenz) ein jeweils 32 x 64 Pixel (ca. 64 km x 64 km am Erdboden) großer Bildausschnitt extrahiert, dessen Zentrum mit der geographischen Position der zum GSR-Wert gehörenden Messstation übereinstimmt (räumliche Korrespondenz). Für jeden dieser Datenpunkte wurden außerdem Monat, Tag und Uhrzeit sowie Längengrad, Breitengrad und Höhe über N.N. der zugehörigen Messstation gespeichert.

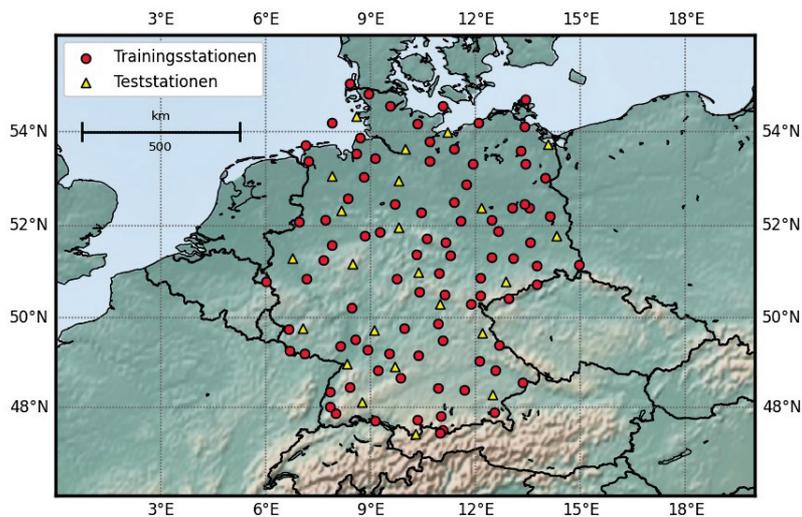


Abbildung 1: Darstellung der Lage der Messstationen in Deutschland. Teststationen werden durch gelbe Dreiecke repräsentiert. Die Messungen der verbleibenden mit roten Kreisen markierten Messstationen wurden weiterhin zufällig einem Trainings- und Validierungsdatensatz zugeordnet.

2.3 Netzwerkarchitektur

Einen Überblick der Netzwerkarchitektur zeigt Abbildung 2. Das Netzwerk sollte so trainiert werden, dass auf Basis (1) des zum Zielort (Ort, für den die Prädiktion erfolgt, siehe unten) gehörenden Ausschnittes des Satellitenbildes zum Zeitpunkt t_i , (2) der geografischen Lage des Zielortes auf der Erdoberfläche, (3) der GSR-Messwerte der zum Zielort benachbarten n Bodenmessstationen zum Zeitpunkt t_i sowie (4) des euklidischen Abstandes und der Höhenunterschiede jeder der n benachbarten Bodenmessstationen zum Zielort der kumulative GSR-Wert vorhergesagt wird, der innerhalb der auf den Zeitpunkt t_i folgenden Stunde am Zielort zu erwarten ist. Für das Training korrespondieren die Zielorte mit der Lage der Trainingsstationen.

Das zur Vorhersage der GSR-Strahlung verwendete neuronale Netzwerk besteht aus einem vortrainierten VGG16-Netz [4] und sich daran anschließenden vollständig verbundenen Schichten (Dense Layer). Das VGG16-Netz dient als Backbone, dessen Parameter im Rahmen des Trainings nicht verändert werden. Es eignet sich zur Ableitung informativer Merkmale aus den Satellitendaten. Der so extrahierte Merkmalsvektor wird mit den weiteren Metadaten des Zielortes verkettet und bildet den Eingang eines Dense-Netzwerkes (DenseNet). Je nach Anzahl n benachbarter Bodenmessstationen beinhaltet dieser Merkmalsvektor auch die Messwerte an diesen Stationen sowie deren o.g. Abstände zum Zielort (Differenzen von Längengrad, Breitengrad und Höhe). Die Anzahl berücksichtigter Nachbarstationen wurde entsprechend des experimentellen Setups variiert (siehe unten). Das DenseNet bestand aus zwei Schichten mit jeweils 256 und 64 Neuronen mit ReLu-Aktivierung. Ausgabe des Netzwerkes ist der kumulierte GSR-Wert am Zielort (d.h. in der Mitte des Satellitenausschnittes), der innerhalb der folgenden Stunde erwartet werden kann.

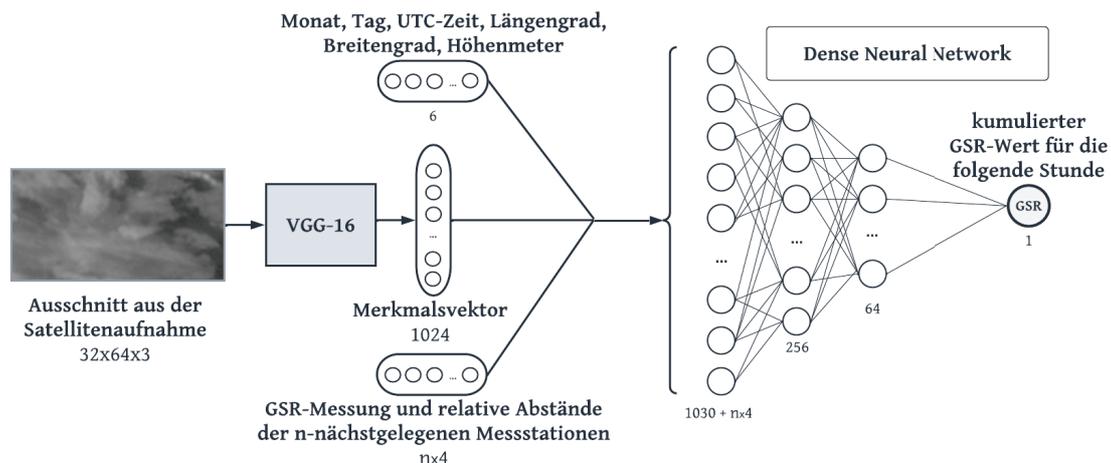


Abbildung 2: Netzwerkkonstruktion zur Vorhersage der in der folgenden Stunde auftretenden GSR. Das um den Zielort zentrierte Satellitenbild wird durch das VGG-16 Netzwerk in einen Merkmalsvektor transformiert. Zusammen mit der geographischen Lage des Zielortes, des Messzeitpunktes sowie den Daten der n nächstgelegenen Stationen erlernt das neuronale Netz den systematischen Zusammenhang zu dem am Erdboden innerhalb der folgenden Stunde am Zielort zu erwartenden kumulierten GSR-Wert.

2.4. Training

Das Training des Modells erfolgte in Keras/Tensorflow (Version 2.3) unter Verwendung des Adam-Optimizers (initiale Lernrate 0,00005), einer Batchgröße von 200 und mit der Zielmetrik mittlerer quadratischer Fehler (MSE) zwischen tatsächlichem und vorhergesagtem GSR-Wert. Während des Trainingsprozesses wurde nach jeder Epoche der MSE auf den Validierungsdaten berechnet. Falls der MSE auf den Validierungsdaten nach 10 Epochen nicht reduziert wurde, wurde die Lernrate des Modells halbiert. Um eine Überanpassung an die Trainingsdaten zu verhindern, wurde das Training frühzeitig gestoppt, falls innerhalb von 20 aufeinanderfolgenden Epochen keine Verbesserung des MSE auf den Validierungsdaten erreicht wurde. Um den Erfolg des Trainingsprozesses zu bewerten, wurde dann das Modell ausgewählt, das über den gesamten Trainingszeitraum den geringsten MSE auf den Validierungsdaten erzielte. Durch das frühzeitige Beenden des Trainings, variierten die Trainingszeiten zwischen 8 und 15 Minuten. Um den Einfluss der Verwendung von GSR-Werten zum Zielort benachbarter Bodenmessstationen zu untersuchen, wurde die Anzahl der jeweils n nahegelegenen und für die Prädiktion zu verwendenden Nachbarstationen systematisch vergrößert. Für jede Anzahl n benachbarter Stationen wurden dabei insgesamt 10 Trainingsdurchläufe absolviert. Zur Evaluierung des Trainings wurde der Fehler zwischen tatsächlichem und geschätztem GSR-Wert mit Hilfe des Root-Mean-Squared-Error (RMSE) für jeden der 10 durchgeführten Trainingsdurchläufe berechnet und über alle Durchläufe gemittelt.

3. Ergebnisse

In Abbildung 3 ist der über die 10 Trainingsdurchläufe gemittelte RMSE für jedes Trainingsszenario abgebildet. Die Grafik zeigt den Einfluss der Anzahl verwendeter nächstgelegener Stationen auf den Vorhersagefehler. Für den Fall 0 zusätzlich verwendeter Stationen entspricht die Vorhersage der Prädiktion des GSR-Wertes allein

anhand des zugehörigen Satellitenbilddausschnittes sowie geografischer Lage des Zielortes und der Messzeit (Monat, Tag, Uhrzeit).

Das Netzwerk erreichte auf den Testdaten ohne weitere Referenzstationen ($n=0$) einen durchschnittlichen RMSE von $80,36 \text{ W/m}^2$. Bei Verwendung von Messdaten der $n=5$ nahegelegenen Stationen verringert sich der RMSE auf $77,24 \text{ W/m}^2$. Eine weitere Zunahme von Referenzstationen ($n>5$) veränderte das Fehlerniveau nur unwesentlich. Der Verlauf des Validierungsfehlers in Abhängigkeit der Anzahl einbezogener Nachbarstationen zeigte einen vergleichbaren Verlauf bei einem Fehlerminimum von $\text{RMSE}=67,8 \text{ W/m}^2$ für $n=5$.

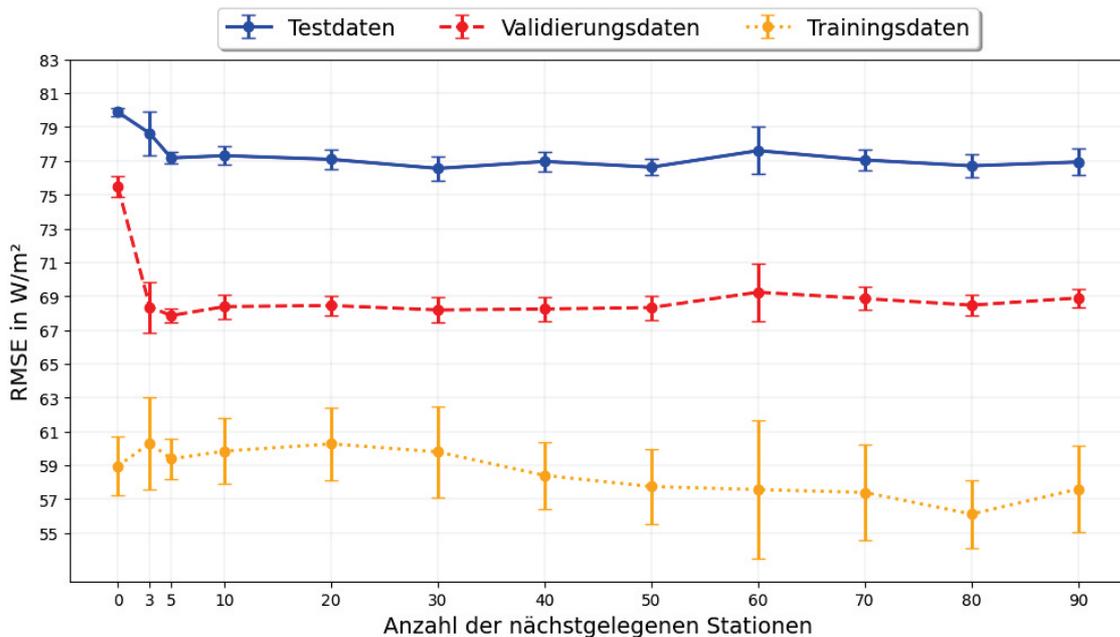


Abbildung 3: Erreichter durchschnittlicher RMSE des Netzwerkes auf Trainings- Validierungs- und Testdaten mit Fehlerbalken. Pro Parametereinstellung der "Anzahl der nächstgelegenen Stationen" wurde das Netzwerk 10-mal trainiert und Mittelwert sowie Standardabweichung des RMSE berechnet.

4. Diskussion

Die Ergebnisse zeigen, dass der vorgeschlagene Deep-Learning-Algorithmus in der Lage ist den Zusammenhang zwischen Satellitendaten im sichtbaren Wellenlängenbereich und Bodenmesswerten der GSR zu erlernen. Unter Hinzunahme von Metadaten konnte eine Genauigkeit erreicht werden, die im Bereich der Ergebnisse existierender Arbeiten liegt [5]. Die Ausnutzung der Korrelation der Messwerte von geographisch nah beieinander liegenden Messstationen durch die Hinzunahme von GSR-Daten umliegender Stationen führte nochmals zu einer Verringerung des Schätzfehlers auf den Testdaten und kann als Mittel zur Verbesserung der Schätzgenauigkeit angesehen werden. Die Ergebnisse zeigen weiterhin, dass eine Hinzunahme von mehr als 5 Nachbarstationen zu keiner weiteren Verbesserung des Schätzfehlers führt. Dies lässt sich auf die abnehmende Korrelation der Messstationen mit zunehmendem geographischen Abstand zueinander zurückführen, da die gemessene GSR u. A. stark von den meteorologischen Einflüssen am Messort abhängt. Weiterhin führt die Einbeziehung einer fest definierten Anzahl von Nachbarstationen aufgrund der

heterogenen Verteilung der Stationen zwangsläufig je nach geographischer Lage zur Abdeckung unterschiedlich großer Gebiete und leistet daher einen Beitrag zur Varianz des Schätzfehlers. Dieser Effekt spielt vor allem bei grenznahen Messstationen eine Rolle, da hier aufgrund der begrenzten Auswahl an Nachbarn auch weiter entfernte Stationen berücksichtigt werden. Um eine präzisere Vorhersage zu ermöglichen, wäre es daher sinnvoll, Nachbarstationen anhand eines festgelegten Radius auszuwählen und die Messungen dieser Stationen je nach Entfernung zum vorherzusagenden Punkt gewichtet zu berücksichtigen.

Darüber hinaus ist die Wiedergabe lokaler Wolkenformationen an einem zu prognostizierenden Standort aufgrund der geringen Auflösung der Satellitenaufnahmen eingeschränkt. Die Auflösung führt dazu, dass feine Details in den Wolkenformationen verloren gehen und eine verallgemeinerte Darstellung der meteorologischen Bedingungen bereitgestellt wird. Dies hat einen negativen Einfluss auf die Vorhersage der GSR-Werte, da die Messstationen lediglich punktuelle Messungen der GSR-Daten liefern, die für die umliegende Umgebung nicht zwingend zutreffend sind. Weiterhin können die Satellitenaufnahmen lokale Wetterverhältnisse nur unzureichend abbilden, wodurch dem Netzwerk wichtige Information zur Vorhersage der GSR fehlen. Eine Verbesserung der Darstellung lokaler Wetterbedingungen und eine Erhöhung der Genauigkeit der Schätzung der GSR könnte demnach durch die Hinzunahme zusätzlicher Informationen, wie Temperatur, Luftfeuchtigkeit und Windgeschwindigkeit, erreicht werden, da diese Faktoren einen wesentlichen Einfluss auf das Wetter und somit auch auf die zukünftig auftreffende Globalstrahlung haben.

In zukünftigen Forschungsarbeiten könnte somit eine systematische Untersuchung des Einflusses ergänzender Messdaten auf die Vorhersagegenauigkeit der globalen Solarstrahlung am Boden erfolgen. Es könnte darüber hinaus sinnvoll sein, geeignete Netzwerkarchitekturen, basierend auf Long Short-Term Memory (LSTM) Netzwerken, einzubeziehen, um eine präzisere Vorhersage der globalen Solarstrahlung für längere Zeiträume zu erreichen. Dies würde es ermöglichen, die von Photovoltaikanlagen gewonnene Energie, insbesondere an Orten ohne Messeinrichtungen, mit höchster Effizienz nutzen zu können.

Quellen und Referenzen

[1] EUMETSAT. *Rapid Scan High Rate SEVIRI Level 1.5 Image Data - MSG*. Online verfügbar über EUMETSAT-User Services Client: <https://archive.eumetsat.int/usc/UserServicesClient.html#sp::delm=O;noti=1;udsp=OPE;qqov=ALL;seev=0>. (Aufgerufen am 31.01.2023)

[2] EUMETSAT. (o. D.). *MSG Level 1.5 Image Data Format Description*. <https://www.eumetsat.int/media/45126>. (Aufgerufen am 31.01.2023)

[3] DWD Climate Data Center (CDC). Historische 10-minütige Stationsmessungen der Solarstrahlung, der atmosphärischen Gegenstrahlung und der Sonnenscheindauer in Deutschland, Version V1, https://opendata.dwd.de/climate_environment/CDC/observations_germany/climate/10_minutes/solar/historical/. (Aufgerufen am 31.01.2023)

[4] Karen Simonyan und Andrew Zisserman. *Very Deep Convolutional Networks for Large-Scale Image Recognition*. (2014). doi:10.48550/ARXIV.1409.1556. <https://arxiv.org/abs/1409.1556>. (Aufgerufen am 06.02.2023)

[5] Jiang, Hou & Lu, Ning & Qin, Jun & Tang, Wenjun & Yao, Ling. (2019). A deep learning algorithm to estimate hourly global solar radiation from geostationary satellite data. *Renewable and Sustainable Energy Reviews*. 114.109327.10.1016/j.rser.2019.109327. (Aufgerufen am 31.01.2023)