



Abschlussbericht vom 28.06.2019

SKYCAM

Lokale Vorhersage der Sonneneinstrahlung



©CSEM 2019



Datum: 28. Juni 2019

Ort: Alpnach

Auftraggeberin:

Bundesamt für Energie BFE
Forschungsprogramm Solare Hochtemperaturrenergie
CH-3003 Bern
www.bfe.admin.ch
energieforschung@bfe.admin.ch

Auftragnehmer/in:

CSEM Center Alpnach
CH-6055 Alpnach Dorf
www.csem.ch

Meteotest AG
CH-3012 Bern
www.meteotest.ch

Autor/in:

Jörg Pierer, CSEM, joerg.pierer@csem.ch
Jan Remund, Meteotest, jan.remund@meteotest.ch

BFE-Bereichsleitung:	Stefan Oberholzer, stefan.oberholzer@bfe.admin.ch
BFE-Programmleitung:	Stefan Oberholzer, stefan.oberholzer@bfe.admin.ch
BFE-Vertragsnummer:	SI/501515-01

Für den Inhalt und die Schlussfolgerungen sind ausschliesslich die Autoren dieses Berichts verantwortlich.



Zusammenfassung

Das Projekt SkyCam hat das Ziel verfolgt, mit Hilfe einer günstigen, Kamera-basierten Lösung die Sonneneinstrahlung auf lokaler Ebene zu bestimmen. Darauf basierend sollte Letztere für einen Zeitraum von mehreren Minuten in die Zukunft prognostiziert werden. Mit dieser Information könnten vor allem sogenannte Inselösungen profitieren, bei welcher Photovoltaik in Kombination mit Diesellgeneratoren zur Stromerzeugung zum Einsatz kommen. Da der Generator nicht permanent in Bereitschaft laufen müsste, könnte durch eine genauere Vorhersage der Verbrauch fossiler Brennstoffe stark reduziert werden.

Mit Abschluss des Projekts stehen komplette Datensätze für die drei Teststandorte in Alpnach, Neuenburg und Bern zur Verfügung. Diese enthalten HDR-Bilder der gesamten Hemisphäre im Abstand von 10 Sekunden ergänzt durch die tatsächliche Sonneneinstrahlung gemessen mit einem Pyranometer. Für den Stereokamera-Standort Bern steht zudem die Wolkenhöhe, gemessen mit einem Ceilometer zur Verfügung. Um weitere Daten zu sammeln bleiben bis auf weiteres alle Stationen auch nach Projektabschluss in Betrieb.

Mit Hilfe eines neuronalen Netzwerks konnte zunächst die Einstrahlungsstärke ausschliesslich basierend auf den Bilddaten bestimmt werden. In einer Erweiterung dieser Algorithmen wurde ein erster Schritt in Richtung Vorhersage möglich. Wie zu erwarten war, nimmt deren Unsicherheit mit zunehmender Prognosezeit zu. Je nach Szenario (Art der Wolken etc.) schwankt die Genauigkeit der Vorhersage und erfüllt die Erwartungen zum Teil sehr gut, zum Teil aber auch nur unzureichend.

Summary

The aim of the SkyCam project was to determine solar radiation at the local level with the aid of a cost-effective, camera-based solution. Based on this, the latter should be predicted for a period of several minutes into the future. With this information, so-called island solutions in which photovoltaics are used in combination with diesel generators to generate electricity could benefit in particular. Since the generator would not have to run permanently on standby, the consumption of fossil fuels could be greatly reduced by more precise prediction.

Upon completion of the project, complete data sets will be available for the 3 test sites in Alpnach, Neuchâtel and Berne. These contain HDR pictures of the entire hemisphere in the distance of 10 seconds supplemented by the actual solar irradiation measured with a Pyranometer. The cloud height, measured with a Ceilometer, is also available for the Berne stereo camera location. In order to collect further data, all stations will remain in operation until further notice, even after project completion.

With the help of a neural network, it was initially possible to determine the irradiance exclusively on the basis of the image data. An extension of these algorithms made a first step towards prediction possible. As was to be expected, their uncertainty increases with increasing forecasting time. Depending on the scenario (type of clouds, etc.), the accuracy of the prediction fluctuates and partly fulfils expectations very well, but partly only insufficiently.

Résumé

L'objectif du projet SkyCam était de déterminer le rayonnement solaire au niveau local à l'aide d'une solution économique et basée sur une caméra. Sur cette base, cette dernière devrait être prévue pour une période de plusieurs minutes à l'avenir. Grâce à ces informations, les solutions dites insulaires, dans lesquelles le photovoltaïque est utilisé en combinaison avec des générateurs diesel pour



produire de l'électricité, pourraient bénéficier en particulier. Comme le générateur n'aurait pas à fonctionner en permanence en mode veille, la consommation de combustibles fossiles pourrait être considérablement réduite par des prévisions plus précises.

A l'issue du projet, des jeux de données complets seront disponibles pour les 3 sites d'essai à Alpnach, Neuchâtel et Berne. Ceux-ci contiennent des images HDR de l'hémisphère entier sur une distance de 10 secondes complétées par l'irradiation solaire réelle mesurée avec un pyranomètre. La hauteur des nuages, mesurée à l'aide d'un Ceilomètre, est également disponible pour la caméra stéréoscopique de Berne. Afin de recueillir d'autres données, toutes les stations resteront en service jusqu'à nouvel ordre, même après l'achèvement du projet.

A l'aide d'un réseau neuronal, il a d'abord été possible de déterminer l'éclairement énergétique exclusivement sur la base des données d'image. Une extension de ces algorithmes a permis de faire un premier pas vers la prédiction. Comme on pouvait s'y attendre, leur incertitude augmente avec l'augmentation du temps de prévision. Selon le scénario (type de nuages, etc.), la précision de la prévision fluctue et répond en partie très bien aux attentes, mais en partie seulement insuffisamment.



Inhaltsverzeichnis

Zusammenfassung.....	3
Summary	3
Résumé.....	3
Inhaltsverzeichnis	5
Abkürzungsverzeichnis	6
1 Einleitung	7
2 Ausgangslage	7
3 Vorgehen und Methode.....	7
4 Resultate.....	8
4.1 Vorbereitende Arbeiten und Datenaufnahme	8
4.2 Datenanalyse.....	9
4.2.1 Bestimmung des GHI aus Bilddaten	10
4.2.2 Vorhersage der GHI auf Basis der aktuellen Bilddaten.....	12
5 Schlussfolgerungen und Ausblick	15
5.1 Schlussfolgerung	15
5.2 Ausblick	16
6 Referenzen	16



Abkürzungsverzeichnis

BFE	Bundesamt für Energie
IEA	International Energy Agency
PV	Photovoltaik
RMSE	Root Mean Square Error
HDR	High Dynamic Range
GPU	Graphics Processing Unit
DNI	Direct Normal Irradiance
GHI	Global Horizontal Irradiance
GRU	Gated Recurrent Unit
RNN	Recurrent Neural Network
DNN	Deep Neural Network



1 Einleitung

Ziel dieses Projektes war eine kurzfristige, präzise Vorhersage der Sonneneinstrahlung auf lokaler Ebene (10-100 Meter). Dies sollte mit günstigen 360°-Industriekameras und einer intelligenten Software realisiert werden. Über einen Zeitraum von 365 Tagen sollten alle 10-15 Sekunden Daten aufgenommen werden. Anwendungsgebiete reichen von Sonnenwärmekraftwerk und Diesel-PV-Systemen bis hin zum privaten Gebrauch für die private Speicheroptimierung.

2 Ausgangslage

Das CSEM verfügte zu Projektbeginn mit der «SkyCam» über Hardware und Softwarealgorithmen, die Wolken erkennen und ihre Bewegung bestimmen können. Das System ist daher in der Lage, die „Sichtbarkeit“ der Sonne direkt lokal zu bestimmen und über das Verfolgen der aktuellen Bewegung der Wolken kurzfristige Voraussagen über deren Veränderung zu machen.

Ziel dieses Projektes war es, die «SkyCam» zu kalibrieren und aus der reinen „Sichtbarkeit“ der Sonne einen Wert für die Einstrahlung (GHI) zu ermitteln und diesen über mehrere Minuten in die Zukunft vorauszusagen. Es wurde dabei eine Unsicherheit bei der Globalstrahlung von unter 20 % RMSE angestrebt. Dies sollte mithilfe von sogenannten Ground-Truth-Daten erreicht werden, welche von Meteotest parallel zu den «SkyCam»-Messungen über den Zeitraum von einem Jahr aufgenommen werden sollten.

Die Firma Meteotest sollte an den Untersuchungsstationen die Globalstrahlung messen. Dazu sollten präzise und geeichte Pyranometer eingesetzt werden, welche zeitlich hohe Auflösungen (10-15 Sekunden) messen und verarbeiten können. Weiterhin sollten am Standort Bern die Daten mit Ceilometer-Messungen vom Unispital Bern verglichen werden, um einerseits die Berechnung der Wolkenbasis zu validieren und andererseits deren Einfluss auf die Vorhersage zu bestimmen.

Das erwartete Ergebnis war ein Softwarealgorithmus, welcher den PV-Stromproduzenten und den Stromnetzbetreibern hilft, die erwartete Stromproduktion mit dem vorausgesagten Stromkonsum abzugleichen. Speziell sollte es PV-Stromproduzenten helfen, ihre Stromproduktion genau über den kurzfristigen Zeitraum von mehreren Minuten vorauszusagen und so Kosten zu optimieren. In (1) wird berechnet, dass ein 1 MWp PV-Kraftwerk in Norditalien mit verbesserter Wettervorhersage ca. 4'000 € pro Jahr einsparen könnte. Ein Gerät im Bereich von CHF 10'000 würde also in ca. 2 Jahren amortisiert. Über die Lebensdauer der PV-Anlage von 20 Jahren könnte ein Betrag von ca. CHF 72'000 eingespart werden.

3 Vorgehen und Methode

Das Projekt baute auf den bereits am CSEM intern durchgeführten Versuchen auf. Dabei kamen eine kommerzielle Kamera von Samsung und ein vom CSEM entwickelter Softwarealgorithmus zur automatischen Bilderkennung zum Einsatz.

Die Software erkannte bereits Wolken, kannte den Himmelsweg der Sonne und die momentane Bewegung der Wolken. Voraussagen der Wolkenbewegung über mehrere Minuten und die Bestimmung der Sonneneinstrahlung waren aber noch nicht möglich. Nebst dem akkuraten Sammeln der Messdaten war dies der Kern dieses Projektvorschlags.

Es ging in diesem Projekt also primär um zwei Punkte:



1. Den Zusammenhang zwischen gemessener Wolkenbildung bzw. „Sichtbarkeit“ der Sonne und effektiver Sonneneinstrahlung herzustellen und letztere direkt aus den Bilddaten zu extrahieren.
2. Den Softwarealgorithmus der «SkyCam» mithilfe der Messungen zu optimieren, um eine Unsicherheit in der kurzfristigen Vorhersage (mehrere Minuten) der Globalstrahlung unter 20 % RMSE zu erreichen.

Diese Punkte sollten erreicht werden, indem die relevanten Wetterdaten über ein ganzes Jahr mit der «SkyCam» und den Pyranometern von Meteotest gesammelt und die notwendigen Algorithmen anschliessend verbessert bzw. entwickelt werden.

4 Resultate

4.1 Vorbereitende Arbeiten und Datenaufnahme

An den Standorten Bern, Neuenburg und Alpnach wurden total vier Stationen installiert (Abb. 1 und Abb. 2). An jedem der Standorte misst ein Pyranometer (kalibrierte Class A Hukseflux SR30) die Globalstrahlung. Am Standort Bern wurden zwei Kameras in einem Abstand von ca. 100 m installiert, welche ein Stereokamerasystem repräsentieren. Nach einer Kalibration beruhend auf den Daten des Ceilometers am Inselspital sollte nach Abschluss der Aufzeichnungsphase versucht werden, die Höhe der Wolkendecke direkt aus den Daten des Stereosystems zu gewinnen.




Abb. 1: Installationsstandorte

Zusätzlich wurde am Standort Alpnach eine Wärmebildkamera installiert, welche der Sonne nachgeführt wird und Bilder im mittleren Infrarot-Spektrum aufzeichnet. In diesem Wellenlängenbereich ist die Abstrahlung der Sonne sehr schwach und die Rückstrahlung der Erdwärme sehr hoch. Während der wolkenlose Himmel praktisch schwarz erscheint, werden Wolken durch die reflektierte Erdwärmeabstrahlung deutlich erkannt.

Alle Systeme befinden sich in einem wetterfesten, temperierten Gehäuse. An jedem Standort wurde ein PC mit ausreichend Rechenleistung und der notwendigen Speicherkapazität für die abgeschätzten Daten eines Jahres, total 96 TB, installiert.



Jeder Standort wurde mit einer Software ausgestattet, welche sowohl die Bilddaten, als auch die Pyranometer-Daten mit einer Periode von 10 Sekunden erfasst und speichert. Die Standardkameras liefern in dieser Zeit eine Bildserie mit jeweils 12 Bildern mit unterschiedlicher Belichtungszeit, aus welchen online HDR-Bilder berechnet werden. Alle Daten werden zusätzlich zur lokalen Speicherung an ein Datenbanksystem gesendet. Alle Stationen werden online überwacht und ein Alarm wird gesendet, falls eines der Systeme ausfallen oder eine Störung vorweisen sollte.



Abb. 2: SkyCam und Pyranometer Installation am CSEM Neuenburg

Nach einer umfangreichen Testphase und vielfältigen Optimierungen sowohl an Hard- als auch Software, wurde die Datenaufzeichnung zum 1. Dezember 2017 gestartet. Obwohl zunächst auf ein Jahr vorgesehen, wurde beschlossen, die Datenaufzeichnung weiterlaufen zu lassen, bis der verfügbar Speicherplatz erschöpft ist (voraussichtlich im Frühjahr 2020) oder anderweitige komplexere Probleme auftreten.

4.2 Datenanalyse

Es hat sich schnell herausgestellt, dass die ursprüngliche Methode basierend auf konventionellen Bildverarbeitungsalgorithmen nicht zielführend sein würde. Stattdessen werden neuronale Netzwerke (Abb. 3) eingesetzt, welche die Daten automatisiert verarbeiten und dabei lernen, den Inhalt der Bilder zu deuten.




Abb. 3: Schematische Darstellung des Trainings mit Hilfe eines neuronalen Netzwerks



Aufgrund der enormen Datenmenge haben wir uns auf Bilder konzentriert, welche am CSEM Alpnach über einen Zeitraum von 8 Monaten aufgenommen wurden. Weiterhin wurde die „Samplingrate“ zunächst auf ein Bild pro Minute reduziert. Anders ausgedrückt: Nur jeder 6. Datensatz wurde verwendet.

4.2.1 Bestimmung des GHI aus Bilddaten

Unser erstes Ziel war es, den aktuellen Strahlungswert (GHI) auf Basis der Bildinformation zu schätzen. Um das Problem zu lösen, wurde eine „semi-supervised“ Lösung entwickelt. Die Schätzung des GHI erfolgt dabei mittels zweier Neuronaler Netzwerke:

- Convolutional Encoder – Decoder Struktur (Autoencoder, vergl. mit Abb. 4)
- Regression Network (Abb. 5)

Zunächst wird mittels „unsupervised Learning“ der Autoencoder trainiert. Die Aufgabe des Netzwerks ist, für jedes einzelne HDR Bild eine sogenannte Repräsentation zu finden (Encoding oder auch Code genannt), die die Information des Bildes möglichst kompakt beschreibt. Technisch wird ein Netzwerk designt, dass aus einem Encoder und einem Decoder besteht. Der Encoder hat die Aufgabe, einen kompakten Code aus dem Eingangsbild zu berechnen, der Decoder muss aus dem Code wieder das ursprüngliche Bild rekonstruieren. Damit wird erreicht, dass alle wichtigen Informationen am Ende des Encoders im sogenannten Bottleneck zur Verfügung steht – aber nicht mehr in Form von Pixeln, sondern als kompakte Repräsentation (Vektor). Nach dem Training wird der Decoder nicht mehr benötigt und es wird im Weiteren nur der Encoder verwendet.




Abb. 4: Schematische Darstellung einer "Convolutional Encoder - Decoder" Struktur (Autoencoder)

Dieser „Vorverarbeitungsschritt“ reduziert massiv die Datenmenge, zum anderen ist dieser Ansatz von grosser Wichtigkeit für die Robustheit und Konvergenz der Netzwerke, die nachfolgend die Vorhersage treffen müssen.

Die Aufgabe des Regression Netzwerks ist es, aus der „Repräsentation“ nun den GHI zu schätzen. Dazu wird mit den Daten des Pyranometers als Ziel trainiert. Das Gütekriterium für die Optimierung des Netzwerks (Training) ist dabei der quadratische Fehler zwischen Vorhersage und gemessenem GHI. Der Input des Regression Networks ist also der Code des Kamerabildes (Repräsentation des Bildes), der Ausgang die GHI normiert auf die Daten des Pyranometers. Das Gesamtsystem sieht dann folgendermassen aus:




Abb. 5: Schematische Darstellung des "Regression Networks" zur Ermittlung der GHI

Das Training der beiden Netzwerke kann separat erfolgen, oder gemeinsam mittels einer kombinierten Gütefunktion.

Mithilfe dieses Netzwerks konnte der Strahlungswert in guter Übereinstimmung mit den Pyranometer-Werten direkt aus der Bildinformation bestimmt werden. Abb. 6 zeigt in blau die gemessene (Pyranometer-Daten) und in orange die aus den Bilddaten ermittelte Einstrahlung. Beide Kurven stimmen recht gut überein.




Abb. 6: Bestimmung der Einstrahlung basierend auf den aufgenommenen Bildern. blau: Pyranometer, orange: Bilddaten (Daten Station Alpnach vom 5. Juli 2018)



4.2.2 Vorhersage der GHI auf Basis der aktuellen Bilddaten

Die nächste Herausforderung ist die Vorhersage der zukünftigen Strahlungsstärke auf der Grundlage vergangener Beobachtungen. Um den zeitlichen Aspekt des Problems anzugehen, wurden rekurrente neuronale Netzwerke eingesetzt (RNN) – im speziellen sogenannte „Gated Recurrent Units“ (GRUs, siehe auch Abb. 7).

Im Gegensatz zu den Feed-Forward Netzwerken, haben RNNs die Eigenschaft, Informationen aus der Vergangenheit für die Vorhersage von Daten zu verwenden – sie haben ein Gedächtnis. Die aus den zeitlich aufeinander folgenden Eingangsbildern erhaltenen Darstellungsvektoren werden schrittweise durch einen GRU-Encoder geleitet. Ähnlich wie der Autoencoder zur Berechnung eines Codes aus den einzelnen Bildern, berechnet der GRU-Encoder einen Code, der den zeitlichen Verlauf der räumlichen Situation am Himmel abbildet. In diesem Code (auch „hidden State“ genannt) sind alle wichtigen Informationen enthalten, die für eine Vorhersage in die Zukunft wichtig sind. Dieser Hidden State wird nun verwendet, um den GRU-Decoder zu initialisieren.

Wie oben beschrieben rekonstruiert der Decoder jetzt nicht mehr nur das aktuelle Bild, sondern er versucht ein Bild zu rekonstruieren, wie es anhand seines antrainierten „Wissens“ in der Zukunft aussehen könnte. Der Decoder erhält also jeweils das aktuelle Bild als Eingabe und prognostiziert das nächst Folgende, aus welchem wiederum die Einstrahlung abgeleitet wird. Für jeden weiteren Schritt in die Zukunft wird das eben prognostizierte Bild als neue Eingabe benutzt. Vorteil dieser Vorgehensweise ist ein dynamischer Vorhersagehorizont, da die Prädiktion beliebig oft ausgeführt werden kann.




Abb. 7: Struktur des Vorhersagenetzwerks. Das reale System berechnet aus dem Bild den Code (wie oben erläutert) und verwendet diese kompakte Repräsentation statt ganzer Bilder. Zur besseren Illustration werden hier aber die Bilder gezeigt.

Um die Vorhersage weiter zu verbessern, wurde versucht, die Eingangsbilder selbst zu optimieren. Anstatt alle 12 Einzelbilder mit unterschiedlichen Belichtungszeiten zu verwenden, wurde aus diesen zunächst ein HDR-Bild gerechnet und dieses als Eingabe in die Netzwerke verwendet. Allerdings mussten wir feststellen, dass die Verwendung aller verfügbaren Einzelbilder zu besseren Ergebnissen führt. Für alle weiteren Tests wurden fortan wieder die Einzelbilder verwendet.

Schließlich bietet die Erhöhung der Tiefe (Anzahl der Stufen bzw. Ebenen vom Eingangsbild bis zum Bottleneck-Layer) der GRU-Encoder-Decoder-Architektur einen weiteren kleinen Gewinn an Vorhersagegenauigkeit bei gleichzeitig gestiegenem Rechenaufwand.



Die resultierenden, optimierten Netzwerke waren in der Lage, die Vorhersage für einen Schritt in die Zukunft relativ gut zu modellieren, solange die Schwankungen in der Einstrahlung nicht allzu extrem waren. Wie in Abb. 8 zu sehen, stimmt die Vorhersage (orange) relativ gut mit dem tatsächlich gemessenen Pyranometer-Wert (blau) überein.




Abb. 8: Erste Vorhersage (eine Minute) basierend auf Bilddaten (orange) im Vergleich mit der tatsächlichen Einstrahlung (blau). Daten von Standort Alpnach am 7. Mai 2018.

Die Vorhersagequalität verschlechterte sich jedoch schnell, sobald weitere Schritte in die Zukunft vorauszusagen waren. Zudem war die Vorhersagegenauigkeit des Algorithmus zu diesem Zeitpunkt sehr stark von der tatsächlichen Wolkensituation abhängig.

In einer weiteren Reihe von Experimenten wurde der Effekt der zeitlichen Auflösung getestet. Für einen Zeitschritt von 10 Sekunden (alle Bilddaten werden verwendet), konnten wir die Vorhersagegenauigkeit pro Schritt verbessern, jedoch verschlechterte sich die zeitliche Vorhersage. Das bedeutet, dass eine 10-Sekunden-Vorhersage genauer war als eine Minuten-Vorhersage im vorhergehenden Test. Dies verwundert jedoch nicht, da es natürlich einfacher ist, einen kleineren Schritt in die Zukunft vorherzusagen. Jedoch verschlechterte sich die Genauigkeit für die Vorhersage um eine Minute unter Verwendung von 6 Schritten im 10-Sekunden-Abstand gegenüber einem Schritt im Minuten-Abstand. Dies liegt daran, dass mit jedem weiteren Schritt ein prognostiziertes Eingangsbild verwendet wird und sich die vorhandenen Unsicherheiten entsprechend potenzieren.

Insbesondere bei stark wechselnder Wolkenformation und damit starker Schwankung der Einstrahlung führte die Verwendung der Netzwerke zu grossen Abweichungen bei der Prognose. Um dem entgegenzuwirken wurde, wie in der Zeitreihenprognose üblich, getestet, ob durch die Kombination mit anderen Algorithmen eine bessere Vorhersagen gelingen kann. Nach diesem Prinzip erstellten wir eine Prognose auf Basis der exponentiellen Glättungsmethode „Holt-Winters“ (2); (3). Nach einigen Experimenten mit Gewichtungsparemtern fanden wir heraus, dass ein einfacher Durchschnitt zwischen dem vorhergesagten Wert der Holt-Winters-Methode und dem unseres Deep-Learning-Modells die besten Ergebnisse brachten.

Im oberen Teil von Abb. 9 ist das finale Resultat für die Prognose über 5 Minuten (blau) zu sehen. Starke Schwankungen werden durch den Algorithmus geglättet, der allgemeine Trend ist jedoch gut zu erkennen. Der aktuelle Algorithmus nutzt für die Prognose 20 Bildserien, welche im Abstand von einer Minute entstanden sind. Das heisst das Wissen aus 20 Datensätzen wird verwendet, um die zukünftigen 5 zu prognostizieren. Für die 5-Minuten Vorhersage werden entsprechend bereits 4 Prognosen neben 16 tatsächliche Messungen verwendet.



Im unteren Teil von Abb. 9 ist die prozentuale Abweichung der vorhergesagten von der tatsächlichen Einstrahlung dargestellt. Für Bereiche mit kleiner absoluter Abweichung aber insgesamt niedriger Einstrahlung (z.B. in der Zeit um 15:30 Uhr) erscheint die relative Abweichung sehr gross. Die absolute Abweichung ist in diesen Bereichen jedoch nicht relevant. Interessanter sind die Abweichungen während starker Schwankungen und insgesamt höherer Einstrahlung, z.B. gegen 12:00 Uhr. Diese schwanken zwischen niedrigen einstelligen relativen Abweichungen und bis zu 100%. Letzteres bedeutet eine nicht akzeptable Über- oder Unterschätzung der Einstrahlung um den Faktor 2.




Abb. 9: Oben: Vorhersage mit verbessertem Modell (blau Messdaten, orange 5 Minuten Prognose); Unten: Prozentuale Abweichung der Vorhersage von der tatsächlichen Einstrahlung. (Daten Station Alpnach vom 5. Juli 2018)



Für die Daten des gesamten Tages aus Abb. 9 zeigt die Tabelle in Abb. 10 die quadratische Mittelwertabweichung des GHI für verschiedene Vorhersagezeiträume. Die prozentuale Abweichung wurde auf Basis der mittleren Einstrahlung des Tages von 184 W/m^2 berechnet, bezogen auf den Standort Alpnach und gerechnet von Sonnenauf- bis Sonnenuntergang.

Data of July 5th 2018

Prediction time	1 min	2 mins	3 mins	4 mins	5 mins
RMSE [W/m^2]	64.26	66.40	68.02	71.94	74.42
RMSE [%]	35	36	37	39	40

Abb. 10: Quadratische Mittelwertabweichung für den Datensatz aus Abb. 9 für verschiedene Vorhersagezeiträume.

Die Veränderung der Wolken am 5. Juli 2018 entspricht einem der am schwierigsten vorherzusagenden Situation im gesamten Datensatz. Ein Datenblock, aufgenommen über mehrere Tage im Winter 2018/19 mit relativ einfacher Wolkensituation liefert deutlich bessere Ergebnisse. In Abb. 11 sind die Mittelwertabweichungen über alle diese Tage gemittelt abgebildet. Die mittlere Einstrahlung lag hierbei bei ca. 250 W/m^2 .

Data of validation set

Prediction time	1 min	2 mins	3 mins	4 mins	5 mins
RMSE [W/m^2]	20.31	21.42	22.53	23.64	24.79
RMSE [%]	8	9	9	9	10

Abb. 11: Quadratische Mittelwertabweichung gemittelt über mehrere Wintertage mit relativ einfacher Wolkenformation

5 Schlussfolgerungen und Ausblick

Die Bestimmung der Einstrahlung aus den Bilddaten funktioniert bereits sehr gut und auch die Vorhersage für 5 Minuten konnte stark verbessert werden. Nach wie vor ist deren Genauigkeit jedoch stark von der aktuellen Wettersituation abhängig und in den meisten Fällen noch viel zu ungenau. Zudem wurden bisher nicht alle Datensätze im 10-Sekunden Abstand genutzt, sondern wie oben beschrieben nur alle 60 Sekunden. Die Bilder der Standorte Bern und Neuenburg wurden bisher nicht ausgewertet.

5.1 Schlussfolgerung

Die angelegten Datensätze mit Bild- und Pyranometer-Daten sind in dieser Form einmalig und sehr wertvoll für die Weiterentwicklung der kamerabasierten Einstrahlungsprognose.

Der Algorithmus zur Extraktion der Einstrahlung aus den Bilddaten funktioniert relativ gut. In diesem Stadium wäre die Entwicklung eines entsprechenden Instruments möglich, jedoch kommerziell nicht



attraktiv. Entsprechende Pyranometer zur Messung der „Global Horizontal Irradiance“ (GHI) sind in ähnlicher Preislage verfügbar. Interessanter wäre ein kamerabasiertes Instrument, welches die „Direct Normal Irradiance“ (DNI) bestimmt. In leicht modifizierter Form sollte der Algorithmus dazu grundsätzlich in der Lage sein, jedoch fehlen für dessen Implementierung die nötigen Referenz-Daten.

Die Genauigkeit der Prognose über einen Zeitraum von 5 Minuten und mehr unterliegt im Moment noch starken Schwankungen und ist vor allem von der Wetterlage (Wolkenart, -formation, etc.) abhängig. Es besteht noch enormes Potential zur Verbesserung mit vielen möglichen Variationen und Ergänzungen der aktuell eingesetzten Algorithmen.

5.2 Ausblick

Grundsätzlich ist die Teilnahme an einem internationalen Vergleichstest am „Plataforma Solar de Almería (PSA)“ organisiert im Rahmen des „IEA, PVPS Task 16, Activity 3.3 All sky camera based forecast benchmark“ möglich.

Es wurde beschlossen, dass das komplette Setup am Standort Bern durch Meteotest nach Almeria transferiert wird. Dort werden zunächst lediglich Datensätze abgespeichert, ohne diese „online“ auszuwerten. Als besonderer Vorteil wird hierbei die anschliessend mögliche Kalibrierung der Strahlungsmessung auf die DNI Messdaten des PSA angesehen. Das CSEM wird die Datenaufnahme in Almeria Software-seitig unterstützen.

Weitere Schritte hinsichtlich Entwicklung der Algorithmen werden derzeit von einem Doktoranden am CSEM verfolgt.

6 Referenzen

1. *Forecasting and Observation: Critical Technologies for System Operations with High PV Penetration*. **Alet, Pierre-Jean**. Munich : 32nd European Photovoltaic Solar Energy Conference and Exhibition, 2016.
2. *Forecasting seasonals and trends by exponentially weighted moving averages*. **Holt, Charles C.** 1, Pittsburgh USA : International Journal of Forecasting, January-March 2004, Bd. 20, S. 5-10.
3. *Forecasting sales by exponentially weighted moving averages*. **Winters, Peter R.** 3, s.l. : Management Science, April 1960, Bd. 6, S. 231-362.