

PV-LEISTUNGSPROGNOSEN: OPTIMIERUNG UND ANWENDUNG

Lukas Gaisberger*¹ und Robert Höller¹

¹FH Oberösterreich, Roseggerstraße 15, 4600 Wels, Tel.: +43 50804 44250
E-Mail: lukas.gaisberger@fh-wels.at, <https://www.fh-ooe.at/campus-wels/>

Kurzfassung: Erzeugungsprognosen stellen den Schlüssel zur Optimierung von Systemen mit erneuerbaren Energieträgern dar. Im Zuge des FFG-Projektes „PV-go-Smart“ wurden Prognosemethoden für die Leistung von Photovoltaik-Anlagen (PV) entwickelt und bewertet. Die Bewertung erfolgte sowohl mit statistischen Methoden als auch anhand von Simulationsstudien zum wirtschaftlichen Mehrwert der Prognosen. Die analysierten Methoden zeigen durchwegs vielversprechende Ergebnisse. Vor allem der Datengetriebene Deep-Learning-Ansatz und das statistische Prognosemodell für PV-Leistungsp prognosen liefern gute Prognosequalität. Die GHI-Prognose mittels All-Sky-Imager befindet sich noch in einem früheren Entwicklungsstadium, zeigt jedoch vor allem in der Simulationsstudie bereits großes Potential.

Keywords: Photovoltaik, Prognose, Optimierung, Forecast

1 Einleitung

Mit dem ständig wachsenden Anteil der Photovoltaik (PV) an der Energieerzeugung gewinnt die umfassende Integration dieser Technologie in das Energiesystem zunehmend an Bedeutung. Im aktuellen Regierungsprogramm ist ein Zubau einer PV-Erzeugungskapazität von 11 TWh bis 2030 verankert. Dies entspricht einer Versiebenfachung der installierten PV-Leistung in Österreich und ca. 1 GW Zubau pro Jahr bis 2030. Die Prognose der Leistung ermöglicht es diese fluktuierend auftretenden Energiemengen besser nutzbar zu machen. Je nach Anwendung werden Prognosen für unterschiedliche Prognosehorizonte, Anzahl der Anlagen, und zeitliche Auflösungen benötigt. In diesem Paper sind die finalen Resultate des FFG-Projektes „PV-go-Smart“, bei dem verschiedenen Prognosemethoden der Solarstrahlung und PV Leistung entwickelt und miteinander verglichen wurden, beschrieben.

2 Prognosemethoden

Im diesem Kapitel werden die in dieser Arbeit angewandten Prognosemethoden für die Leistung von Photovoltaik-Anlagen beziehungsweise die Globalstrahlung an einzelnen Standorten beschrieben. Bei den verschiedenen Methoden wurde auf unterschiedliche Datenquellen zurückgegriffen, wodurch sich unterschiedliche Prognosehorizonte und –auflösungen ergeben. Ein wesentlicher Unterschied hinsichtlich der Prognoseergebnisse ergibt sich daraus, dass mithilfe des All-Sky-Imagers bisher nur die Globalstrahlung prognostiziert wurde. Für die datenbasierten Modelle (MOS und Deep-Learning) wurde der Anlernzeitraum auf die Daten von Juli 2017 bis Juni 2018 eingeschränkt.

2.1 PV-Leistungsprognose mit statistischem Prognosemodell (MOS)

Beim MOS (Model Output Statistics) – Verfahren wird, wie bereits bei der Prognose von meteorologischen Parametern üblich, das Verhalten des Zielparameters (AC-Leistung am Ziel-Wechselrichter) innerhalb eines definierten Zeitraums mithilfe multilinearer Regression mit der numerischen Wetterprognose (GFS) verglichen. Auf Basis des trainierten Algorithmus kann danach von den Ergebnissen des GFS-Modells auf die PV-Ausgangsleistung geschlossen werden. Für die hier dargelegten Prognosen wurde ein GFS Modell mit einer räumlichen Auflösung von 0,25 Grad verwendet, wodurch besonders kleinräumige Unterschiede besser prognostiziert werden können. Es wurden pro Tag 4 Prognoseläufe (0, 6, 12 und 18 Uhr) für die kommenden 72 Stunden mit einer zeitlichen Auflösung von 1 Stunde durchgeführt. Neben Prognosen für Einzelanlagen wurde auch die Anwendung dieser Methode auf aggregierte Daten von mehreren Hundert Anlagen untersucht.

2.2 PV-Leistungsprognose mit Deep-Learning Modell (Kurzzeit)

Im Zuge dieser Arbeit wurde ebenfalls versucht Kurzfristprognosen (Nowcast) alleinig mit zum Prognosezeitpunkt zur Verfügung stehenden historischen und aktuellen Messdaten zu erstellen. Diese Messdaten beschränken sich im vorliegenden Modell auf die Wetterdaten verschiedener Wetterstationen in Oberösterreich, sowie den AC-Leistungsdaten aller verfügbaren Wechselrichter. Der Trainingszeitraum wurde, wie auch bei den MOS Modellen, auf einen Zeitraum von einem Jahr beschränkt. Für das darauffolgende Jahr werden Prognosen für die Zeithorizonte 5, 10, 15, 20, 30, 60 und 120 Minuten erstellt. Die Vorverarbeitung der Daten ist für die Prognosequalität von elementarer Bedeutung. Durch automatisierte Preprocessing-Methoden wird für jeden Prognosehorizont das Vorverarbeitungs-Modell mit der kleinsten erwarteten Abweichung zwischen Prognose und Messwert gewählt, welches für alle weiteren Prognoseläufe verwendet wird. Die Modelle unterscheiden sich in der Komplexität ihrer Struktur sowie in der Anzahl der berücksichtigten Anlagen und der unterschiedlichen Gewichtung der Eingangsparameter.

Im Zuge der Arbeit wurde ein neuer Ansatz zur Normierung der Leistungsdaten (Eta-Clear-Sky) entwickelt, welcher ohne die Angabe der Ausrichtung und Neigung der Anlage auskommt, bzw. diese implizit aus dem Leistungsverlauf berücksichtigt.

Für die Prognoseerstellung wurden die Vorverarbeitungsmethoden mit Varianten folgender Methoden kombiniert:

- Lasso, oder 'Least absolute shrinkage and selection operator', ist ein Regressionsmodell das mittels einer L1-Regularisierung der Gewichte eine Merkmalsselektion durchführt und dadurch interpretierbarere statistische Modelle liefert.
- Multilayer Perceptron (MLP): Ein neuronales Feedforward-Netzwerk, das auf Backpropagation zur Bestimmung der Gewichtsparameter basiert.

2.3 Globalstrahlungsprognose mit All-Sky-Imager

Zur Kurzfristprognose (Nowcasting) wurde ein Prognosealgorithmus für All-Sky-Imager entwickelt [1]. Dabei nimmt eine spezielle Fischaugenkamera (All-Sky-Imager) in

regelmäßigen zeitlichen Abständen Fotos der Hemisphäre des Himmels auf, anhand derer die Globalstrahlung bzw. die PV-Leistung für einen Zeitraum von bis zu einer Stunde prognostiziert werden kann. Im Rahmen des Projektes wurden 4 Kameras im Raum Wels installiert. Im Allgemeinen nutzt der All-Sky-Imager die Informationen des sichtbaren Himmels und kann Wolkenereignisse oder die Abwesenheit von Wolken vorhersagen. Der Prognosefehler steigt mit zunehmendem Zeithorizont, wobei der Prognosefehler für sehr kurze Horizonte zwar kleiner als für längere Horizonte ist, die Prognose jedoch erst ab einigen Minuten die Persistenz zu übertreffen beginnt. Die Hauptaufgaben eines kurzfristigen Prognosesystems sind die Wolkenerkennung und die Schätzung der Wolkenbewegung. Für die Wolkendetektion wird der Unterschied in der Lichtstreuung von Wolken gegenüber dem klaren Himmel verwendet. Der Ansatz, der ein Pixel basiertes Rot-Blau-Verhältnis (Red-Blue-Ratio, RBR) verwendet erwies sich als am besten geeignet, die Wolken in verschiedenen Wetter- und Beleuchtungssituationen vom klaren Himmel zu unterscheiden. Das RBR wurde mit einer vorher erstellten Clear-Sky-Library (CSL) korrigiert (Abbildung 1). Unter einer Vielzahl von Techniken zur Abschätzung von Wolkenbewegungen, die in den letzten Jahren auch für Satellitendaten entwickelt wurden, erwies sich die Kreuzkorrelation als am besten. Mit Hilfe dieser Technik wurden Wolkenvektoren berechnet, mit denen die Wolkenbewegung vorhergesagt wird. Obwohl die kurzfristige Vorhersage mit All-Sky-Imager gute und vielversprechende Ergebnisse zeigt, gibt es eine Liste von Problemen, an denen noch gearbeitet wird: Vorhandensein von Regentropfen auf der Glaskuppel der Kamera [1], Wolkenverstärkungseffekt, Variabilität der optischen Eigenschaften der Wolken, spontane Wolkenbildung und -auflösung, und mehrere Wolkenebenen. Im Kapitel 3.3 werden die statistischen Resultate der Kurzfristprognosen auf der Basis der All-Sky-Imager Bilder dargestellt.




Abbildung 1: Wolkendetektion: Originalbild (links) , RBR/RBR-CSL_{modiff} (mitte), endgültige Wolkenmaske (rechts)

2.4 Persistenz

Um die Einschätzung der Prognosemethoden zu erleichtern werden diese in Kapitel 3 mit Persistenz-Methoden verglichen. Im Falle der Kurzfristprognosen (Deep-Learning und All-Sky-Imager) bedeutet Persistenz, dass die Prognose gleich dem aktuellen Messwert ist. Für die MOS Prognose wird ein Persistenz-Modell verwendet, bei welchem die Prognose für den aktuellen Tag der Messung des Vortages entspricht. Die Persistenz stellt damit eine sehr einfache Form der Prognose dar, welche von einer optimierten Prognosemethode übertroffen werden soll.

2.5 Fehlernormen

Im Folgenden werden die zur Qualitätsbewertung angewandten Fehlernormen erläutert.

Die Differenz jedes einzelnen Prognosewertes zum zugehörigen Messwert (ε_i) wurde wie in Formel (1) dargestellt berechnet.

$$\varepsilon_i = P_{pred,i} - P_{meas,i} \quad (1)$$

Dabei ist $P_{pred,i}$ der prognostizierte Wert und $P_{meas,i}$ der gemessene Wert. Die mittlere Abweichung ($\bar{\varepsilon}$) wurde mit Formel (2) berechnet.

$$Bias = \bar{\varepsilon} = \frac{1}{N} \sum_{i=1}^N (P_{pred,i} - P_{meas,i}) = \frac{1}{N} \sum_{i=1}^N \varepsilon_i \quad (2)$$

Diese Fehlernorm wird verwendet um systematische Fehler aufzuzeigen. Die Berechnung des mittleren absoluten Fehler wird mithilfe von Formel (3) berechnet.

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_{pred,i} - P_{meas,i}| = \frac{1}{N} \sum_{i=1}^N |\varepsilon_i| \quad (3)$$

Diese Fehlernorm gibt Auskunft darüber wie weit die Prognose im Mittel von der Messung abweicht. Der MAPE (Mean Absolute Percentage Error) oder Percentage Error wird mit Formel (4) berechnet.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{(P_{pred,i} - P_{meas,i})}{P_{meas,i}} \right| = \frac{1}{N} \sum_{i=1}^N \left| \frac{\varepsilon_i}{P_{meas,i}} \right| \quad (4)$$

Dieser gibt den relativen Fehler in Bezug auf den Messwert wieder und muss zusätzlich in Prozent umgewandelt werden. Um Prognosen für verschiedene Anlagen zu vergleichen wird der rMAE mit Formel (5) berechnet.

$$rMAE = \frac{1}{N} \cdot \frac{1}{\text{mean}(P_{meas})} \cdot \sum_{i=1}^N |P_{pred,i} - P_{meas,i}| = \frac{1}{N} \cdot \frac{1}{\text{mean}(P_{meas})} \cdot \sum_{i=1}^N |\varepsilon_i| \quad (5)$$

Dabei wird der MAE auf den Mittelwert aller Messwerte (P_{meas}) relativiert.

3 Ergebnisse

Im folgenden Kapitel wird die Prognosequalität der verschiedenen Methoden beschrieben. Dabei ist zu berücksichtigen, dass sich die Prognosen in wesentlichen Punkten unterscheiden und die Ergebnisse daher teilweise nicht unmittelbar vergleichbar sind.

Vor der Bestimmung der Prognosequalität wurden alle Mess- und Prognosewerte unter 1 W gefiltert, da diese nicht aussagekräftig sind und zu hohen relativen Fehlern führen können. Außerdem wurden damit die Nachtstunden aus der Evaluierung ausgeschlossen. Zeitpunkte ohne Mess- bzw. Prognosewert wurden ebenfalls aus der Qualitätsanalyse ausgeschlossen. Dies betrifft vor allem die Globalstrahlungsprognose mit All-Sky-Imager (Kapitel 3.3), da der Prognosealgorithmus bei schlechter Bildqualität und –verfügbarkeit sowie zu hohen Wolkengeschwindigkeiten oftmals kein Ergebnis erzielt. Dieses Verhalten des Algorithmus beeinflusst die Prognosequalität enorm, da „schwierige“ Prognosen ausgelassen werden müssen.

Beim Vergleich einer Prognosemethode an verschiedenen Standorten wird der Einfluss der lokalen Wetterbedingungen auf die Prognosequalität ersichtlich. Standorte mit gemäßigt

Wetter, einfacher Orografie und wenig Nebel ermöglichen eine wesentlich genauere Prognose.

Um Informationen über die Bandbreite der Abweichungen zu bekommen werden teilweise Boxplots erstellt. Alle Abweichungswerte zum jeweiligen Prognosehorizont sind durch die strichlierten Linien begrenzt. Die rote Linie zeigt den Median der Abweichungen und die blaue Box ist durch das obere und untere Quartil begrenzt. Somit befinden sich 50 % aller Werte innerhalb der blauen Begrenzung. Der Mittelwert der dargestellten Bandbreite ist mit einem Kreuz markiert.

3.1 PV-Leistungsprognose mit statistischem Prognosemodell (MOS)

Das statistische Prognosemodell stellt eine Methode für Prognosehorizonte von 0-72 h bei stündlicher Auflösung dar. Sofern nicht anders beschrieben wird bei der Darstellung der Ergebnisse der Prognoselauf, der um 0 Uhr UTC startet (0 Uhr-Lauf) betrachtet. Für derartige Prognosen die auf numerischen Wetterprognosen basieren ist vor allem das Prognosefenster von Stunde 25 – 48 (Day-Ahead) interessant. Es werden stündliche Mittelwerte der Leistung prognostiziert. Beispielsweise stellt der Wert bei Stunde 5 nach Prognoselauf den Mittelwert zwischen Beginn der Stunde 4 und Beginn der Stunde 5 dar.

In Abbildung 2 und Abbildung 3 ist der relative MAE bezogen auf den Mittelwert aller Messwerte für die Persistenz und die MOS-Prognose dargestellt.

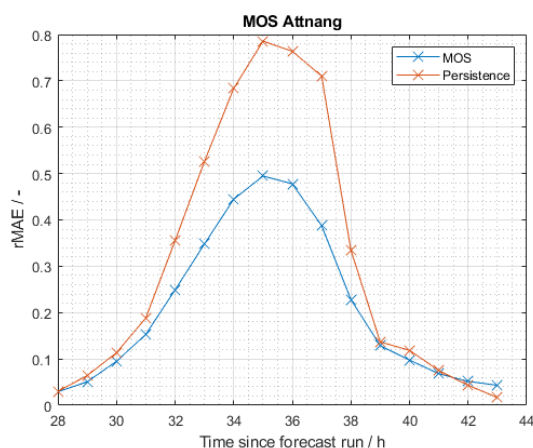


Abbildung 2: Standort Attnang, rMAE von MOS und Persistenz

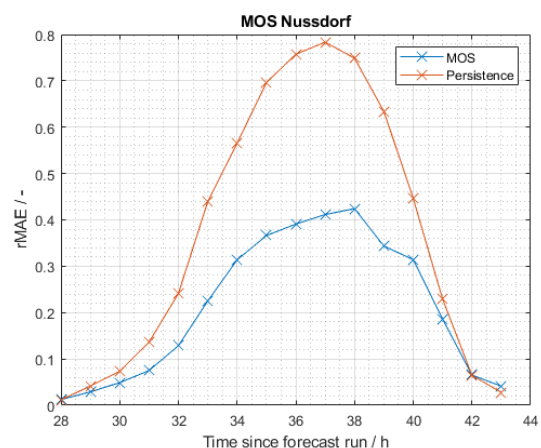


Abbildung 3: Standort Nussdorf, rMAE von MOS und Persistenz

Der höchste rMAE tritt typischerweise um die Mittagszeit auf, da dort die höchsten Leistungswerte erzielt werden. Auffällig ist, dass die Persistenz-Prognose in den Abendstunden im Durchschnitt genauer ist, als die MOS-Methode. Dies ist darauf zurückzuführen, dass im Trainingszeitraum nur wenige Datenpunkte für diese Tageszeit zur Verfügung stehen. Vor allem in Phasen mit höherer PV-Leistung zeigt das statistische Prognosemodell deutlich geringere Abweichungen als die Persistenz. Auffällig ist, dass das Maximum am Standort Nussdorf ca. 2 Stunden später auftritt als am Standort Attnang. Dies liegt höchstwahrscheinlich an der Ausrichtung der Anlage.

Das Diagramm in Abbildung 4 zeigt den prozentuellen Fehler in jeder Stunde des Prognosezeitraums.

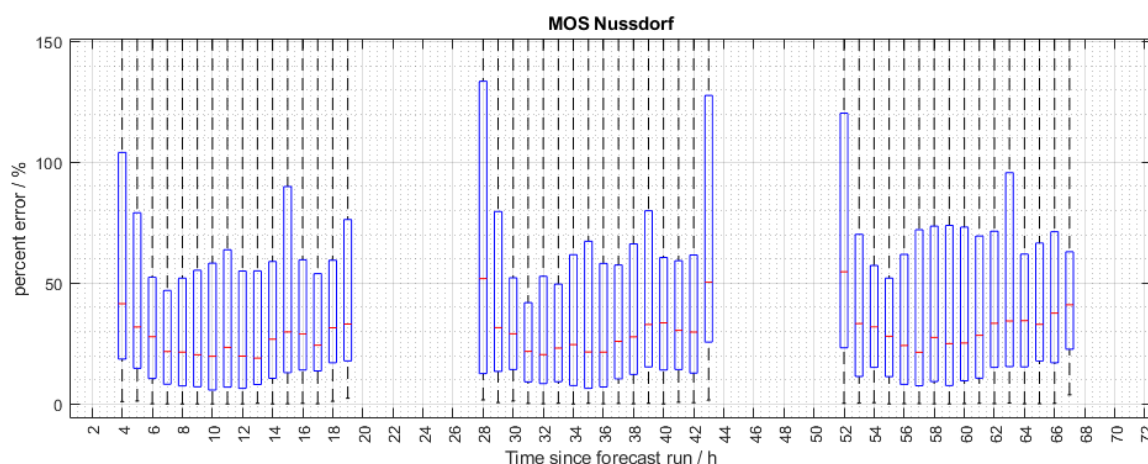


Abbildung 4: MOS Nussdorf, Boxplot des prozentuellen Fehlers für jede Stunde der gesamten Prognoseperiode

Vor allem in den Morgen- und Abendstunden ist der prozentuelle Fehler höher, da die Messwerte geringer sind. Auffällig ist außerdem der geringe Unterschied der Prognosefehler zwischen Tag 1 und Tag 3. Der erhöhte Fehler bei Stunde 15, 39 und 63 deuten auf systematische Fehler beziehungsweise schlechte Trainingsdaten hin. In Tabelle 1 ist der Mittelwert der Messwerte sowie die Ergebnisse verschiedener Fehlernormen, welche in Kapitel 2.5 näher beschrieben sind, für die Day-Ahead Prognose des 0 Uhr UTC Laufs eingetragen.

Tabelle 1: Ergebnisse der Qualitätsbewertung der Day-Ahead Prognose des 0 Uhr Laufs

| | meas | bias | MAE | rMAE | MAPE |
|-------------------|---------|--------|---------|------|------|
| Thalheim | 998.50 | 29.60 | 261.54 | 0.25 | 1.03 |
| Nussdorf | 1284.26 | -34.32 | 351.17 | 0.26 | 1.21 |
| Lenzing | 1295.40 | 39.39 | 402.49 | 0.29 | 1.36 |
| Wels | 645.51 | -55.97 | 201.42 | 0.29 | 1.02 |
| Attnang | 977.82 | -49.53 | 263.84 | 0.26 | 0.66 |
| Aggregiert | 8641693 | 245230 | 2195596 | 0.25 | 0.67 |

Es können deutliche Unterschiede zwischen den Anlagen festgestellt werden. Die sich aus den bereits erwähnten Fehlerquellen ergeben. Der relative mittlere Fehler bewegt sich im Bereich zwischen 0.25 und 0.29. Die Prognose der aggregierten Leistung von mehreren hundert Anlagen erreicht ebenfalls eine sehr gute Qualität. Dies kann damit begründet werden, dass sich Fehler, die bei Einzelanlagen auftreten, teilweise aufheben.

3.2 PV-Leistungsprognose mit dem Deep Learning Modell (Nowcasting)

Der Ansatz zur Kurzfrist-Prognose von PV-Leistung mittels Deep Learning (DL)-Methoden zeigt im Vergleich zur Persistenz-Prognose deutliche Verbesserungen der Prognosequalität bei allen Zeithorizonten. In Abbildung 5 und Abbildung 6 ist der relative mittlere absolute Fehler (rMAE) bezogen auf den Mittelwert aller PV-Leistungswerte die größer als 1 W sind für die DL-Methode sowie für die Persistenz-Methode für verschiedene Prognosehorizonte aufgetragen.

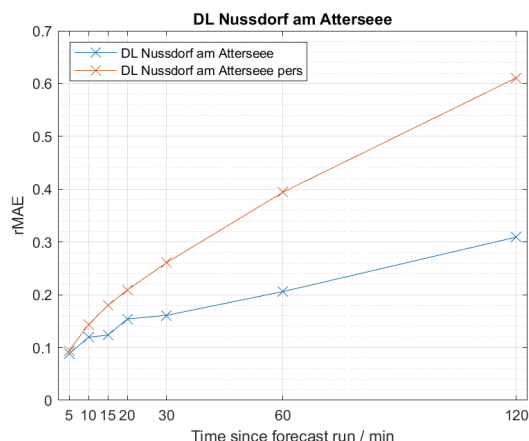


Abbildung 5: Vergleich rMAE zwischen DL und Persistenz für Standort Nussdorf

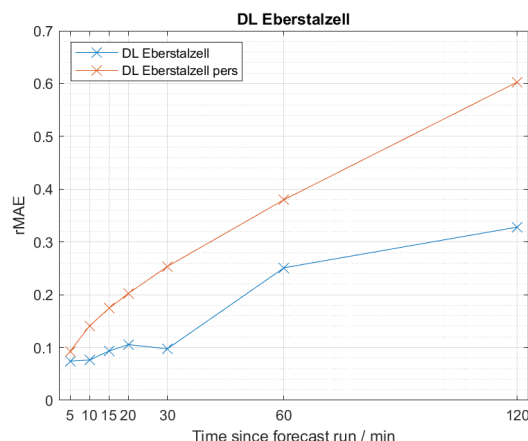


Abbildung 6: Vergleich rMAE zwischen DL und Persistenz für Standort Eberstalzell

Bereits ab einem Prognosehorizont von 5 Minuten zeigt der datengetriebene Machine-Learning-Ansatz deutlich kleinere Fehler als die Persistenz. Bei einigen Standorten fällt auf, dass der Prognosefehler nicht wie erwartet stetig größer wird, je länger der Prognosehorizont ist, sondern in manchen Fällen auch geringfügig absinkt. Dieses Phänomen ist beispielsweise beim Standort Eberstalzell in Abbildung 6 für den Zeithorizont 30 Minuten zu beobachten. Ein derartiges ungewöhnliches Verhalten ist auf die automatisierte Auswahl des optimalen Machine-Learning Modells auf Basis des Trainingszeitraums zurück zu führen. Bei der Modellauswahl gibt es also Fälle in denen die genaueren (und komplexeren) Modelle nicht konvergieren und daher von robusteren, ungenaueren Modellen abgelöst werden. Ein Ansatz für die Lösung dieses Problems ist das häufigere und bessere Training des Trainingsdatensatzes.

Abbildung 7 zeigt die Abweichungen für jeden Prognosehorizont am Beispiel einer Anlage mit Standort Lenzing mit einer Peakleistung von 5 kWp.

Der Mittelwert sowie der Median der Abweichung zwischen Prognose und Messwert befinden sich bei dieser Prognosemethode innerhalb des Bereichs von -7 bis +22 W. Die Maximale Abweichung beträgt beim Standort Wels ca. 2 000 W, wobei diese Extremwerte nur äußerst selten Vorkommen und daher teilweise auf Messfehler, oder Ausfälle zurückzuführen sind.

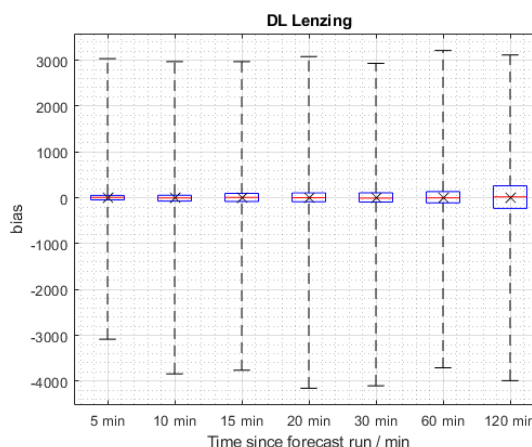


Abbildung 7: Fehler (Box) und mittlerer Fehler (x) der DL-Methode für Standort Lenzing

In Abbildung 8 ist der MAPE (Mean Absolute Percentage Error, Formel (4)) für jede Tagesstunde (UTC) abgebildet. Dieser ist aufgrund der geringen Leistungen in den Morgen- und Abendstunden, welche im Winter teilweise auf null sinken, deutlich höher als im restlichen Tagesverlauf. Der Median des MAPE bleibt zu jeder Tagesstunde unter 40 %. In Tabelle 1 sind Ergebnisse der DL-Prognosen für alle Standorte zusammengefasst.

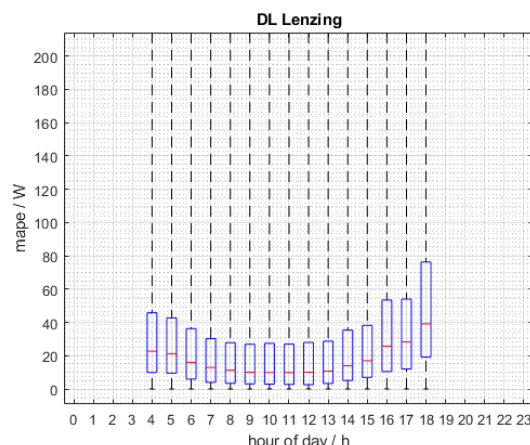


Abbildung 8: Prozentueller Fehler DL-Methode für Standort Lenzing

Um die Ergebnisse vergleichbarer zu machen, wurde der rMAE auf die mittlere Leistung der Anlage (meas) bezogen. Aus der Tabelle geht hervor, dass am Standort Wels die kleinste PV-Anlage installiert ist, diese jedoch die vergleichsweise schlechteste Prognosequalität aufweist. Die höchste Prognosegenauigkeit bezogen auf die mittlere Leistung wird in Eberstallzell mit einem rMAE von 0.14 erreicht. Die niedrigste mittlere relative Abweichung wird am Standort Lenzing mit MPAE = 0.33 erzielt.

Tabelle 2: Ergebnisse der Qualitätsbewertung der DL-Methode

| | meas | bias | MAE | rMAE | MAPE |
|-----------------------------|---------|--------|--------|------|------|
| Eberstallzell | 1495.43 | -14.28 | 214.18 | 0.14 | 0.35 |
| Lenzing | 1395.20 | 2.08 | 214.85 | 0.15 | 0.33 |
| Nussdorf a. Attersee | 1389.05 | -0.22 | 239.03 | 0.16 | 0.42 |
| Thalheim | 1078.82 | 0.01 | 207.87 | 0.19 | 0.41 |
| Wels | 678.97 | -6.84 | 150.54 | 0.21 | 0.82 |

3.3 Globalstrahlungsprognose mit All-Sky-Imager

Im folgenden Kapitel wird die Prognosemethode mittels All-Sky-Imager bewertet. Aufgrund verschiedener Einflussfaktoren wie zu hohe Wolkengeschwindigkeit, Datenlücken und optische Störungen kann der entwickelte Algorithmus teilweise keine Werte abgeben. In Tabelle 3 ist die Anzahl der Datenpunkte mit finiten Werten je Prognosehorizont dargestellt.

Tabelle 3: Prognoseverfügbarkeit je Zeithorizont

| Horizont | 5 min | 10 min | 15 min | 20 min | 25 min | 30 min |
|-----------------------------------|-------|--------|--------|--------|--------|--------|
| Anz. finiter Prognosewerte | 68254 | 60045 | 53626 | 48628 | 43840 | 40563 |

Aufgrund der deutlichen Unterschiede zwischen den Prognosehorizonten wurden für die weiteren Auswertungen nur die Prognoseläufe bei denen alle Zeitschritte vorhanden sind verwendet. Dabei ist jedoch die Problematik hervor zu heben, dass dadurch „schwierige“ Prognoseläufe mit tendenziell größeren Fehlern in der Auswertung nicht berücksichtigt werden.

Die Auswertung der Abweichungen (ε_i) in positive und negative Richtung ist im Boxplot in Abbildung 9 dargestellt. Anhand dieser Darstellung kann abgeleitet werden, dass bei dieser Prognosemethode kein systematischer Fehler hinsichtlich des Zeithorizonts vorliegt.

Die Auswertung der gesamten Prognosedaten zeigt, dass die Persistenz-Prognose im Bereich von 5 bis 10 Minuten häufig bessere Ergebnisse liefert als der All-Sky-Imager. Dies liegt zum Teil daran, dass die globale Horizontalstrahlung (GHI) bei der Methode nur berechnet, jedoch nie gemessen wird, sich diese aber innerhalb der kurzen Prognosehorizonte kaum ändert.

In Abbildung 10 ist der Vergleich für einen der wenigen Tage abgebildet an dem die All-Sky-Imager-Prognose bereits ab Minute 10 einen kleineren Fehler als die Persistenz aufweist.

3.4 Vergleich

Aufgrund unterschiedlicher Zeithorizonte und zeitlicher Auflösung, Prognoseverfügbarkeit, und Prognosezielwert wird ein Vergleich der All-Sky-Imager Prognose mit den anderen Methoden unnötig.

In Abbildung 11 wird versucht die beiden Methoden Deep-Learning und MOS für den Standort Wels zu vergleichen. Bis zu einem Prognosehorizont von 1 Stunde weist die Deep-Learning Methode einen geringeren Fehler auf, jedoch ist das statistische Prognosemodell ab Stunde 2 genauer. Der Vergleich dieser beiden Prognosemethoden ist ebenfalls nicht ganz korrekt, da die Deep-Learning Methode alle 5 Minuten einen Prognoselauf für die nächsten 2 Stunden startet, das MOS Modell jedoch nur alle 6 Stunden eine Prognose für die nächsten 72 Stunden erstellt.

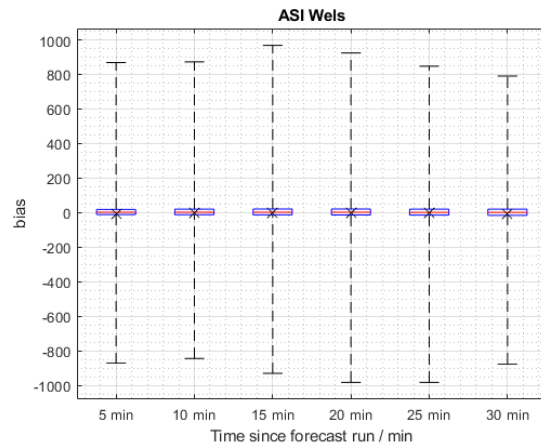


Abbildung 9: All-Sky-Imager Wels, Abweichung der Prognose vom Messwert zur Feststellung systematischer Fehler

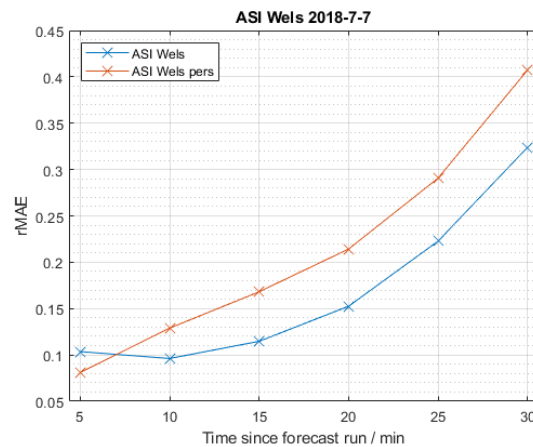


Abbildung 10: All-Sky-Imager Wels, Vergleich mit Persistenz für einen Tag




Abbildung 11: Vergleich von DL und MOS für Standort Wels

4 Anwendungen

Im Rahmen der Prognoseauswertung wurden neben der statistischen Bewertung Simulationsstudien durchgeführt. Deren vorläufige Ergebnisse werden in diesem Kapitel kurz dargestellt.

4.1 Diesel-Hybrid System

Für die Nowcasting-Methoden (Deep-Learning und All-Sky-Imager) wurde die Anwendung in einem Inselsystem mit einer PV-Anlage, zwei Dieselaggregaten und einer vorgegebenen Lastkurve simuliert. Durch eine Prognose der PV-Leistung kann die nötige Leistungsreserve der Dieselgeneratoren reduziert werden. Dies führt zu einer Reduktion der Verluste durch Einspeisebegrenzung, zu geringeren Laufzeiten der Aggregate und zu höheren Wirkungsgraden durch Verminderung des Teillastbetriebs. Die Ergebnisse dieser Simulationen wurden bereits in [2] dargestellt und bringen eine Reduktion der Betriebskosten von ca. 3 %.

4.2 Einfamilienhaus

Die MOS-Methode wurde für den optimierten Betrieb eines Einfamilienhauses mit PV, Stromspeicher und variablem Bezugs- und Einspeisetarif angewandt. Diese Simulationsstudie wurde ebenfalls in [2] beschrieben. Durch die Aktualisierung der Strompreise und Veränderungen am Modell konnte in den neuesten Simulationen jedoch nur noch eine Kostenreduktion von 1,9 % bei realer PV-Prognose und perfekter Lastprognose erreicht werden.

5 Zusammenfassung

Zusammenfassend kann gesagt werden, dass das Deep-Learning Modell und das statistische Modell bereits sehr gute Prognoseergebnisse aufweisen, jedoch weitere Verbesserungen möglich wären. Es wurde ein neuer Algorithmus für All-Sky-Imager entwickelt, welcher bereits vielversprechende Ergebnisse liefert. Auf den gewonnenen Erkenntnissen kann aufgebaut werden um diesen Algorithmus zu verbessern und weiter zu entwickeln. Insbesondere soll in nächsten Schritten die Wolkenhöhe, Wolkentypen und Variabilität der optischen Eigenschaften der Wolken im Algorithmus berücksichtigt werden - Parameter die in der derzeitigen Version noch als konstant angenommen wurden.

6 Quellen

- [1] Voronych, O., Höller, R., Longhi Beck, G. and Traunmüller, W., Solar PV Nowcasting based on Skycamera observations, *Adv. Sci. Res.*, **16**, 7–10, 2019, <https://doi.org/10.5194/asr-16-7-2019>.
- [2] Gaisberger, L., Höller, R., Rechberger, P., Voronych, O., Traunmüller, W., Backmann, M., Diewald, N., Vattapally, M., Praher, P., Ehrlinger, M. Rodin, V., and Moser, S., Performance Test of new PV forecasting models in realistic environments, *Proc. EUPVSEC*, Marseille, 1432-1436, 2019.