

Bedeutung von Prognosen für die Energiewende

1. Die Bedeutung von Prognosen für die Energiewende

Um die Klimaschutzziele der Bundesregierung zu erreichen, muss der Anteil der fluktuierenden erneuerbaren Energien (FEE: Windenergie und Photovoltaik) weiter zunehmen. Das Stromsystem muss so aufgebaut werden, dass die fluktuierend anfallenden Strommengen wirtschaftlich und unter Wahrung der Versorgungssicherheit integriert werden können.

Da Windenergie- und Photovoltaikanlagen vermehrt an komplexeren Standorten wie Waldgebieten, bergigem Gelände bzw. Regionen mit viel Nebel und Schnee errichtet werden, nehmen die Anforderungen an Ertragsprognosen stetig zu. Mit wachsender Prognosegüte wird dabei die Standortwahl verbessert und das Risiko für Investitionen reduziert. Dies wiederum wirkt sich positiv auf die Kapitalkosten aus, die einen erheblichen Anteil an den Gesamtprojektkosten ausmachen.

Für eine bessere Integration von Neuanlagen spielt jedoch vor allem die Güte von Langfristprognosen bezüglich des zeitlichen Einspeiseprofils eine entscheidende Rolle. Hierfür müssen die Methoden für die Korrelation zwischen historischen Wettermodell- und dem Messzeitraum verbessert werden und die Art der Sensoren, die in die Vorhersagen einfließen, erweitert werden, um den Vorhersagezeitraum sowohl in den Kurzfrist- wie auch den Langfristbereich zu erweitern.

Auch der bisher vorherrschende Zeitbereich der heutigen Prognosen (Day-ahead) muss in seiner Vorhersagegenauigkeit verbessert werden, um die Ausgleichsenergiekosten für Windenergie- und Photovoltaikanlagen in der Direktvermarktung zu senken.

Die Einspeisung einer zunehmenden Zahl von EE-Anlagen ist nicht mehr allein durch das Wetter bestimmt, sondern hängt von diversen weiteren Einflussfaktoren der netzbedingten Abregelung oder der Eigenversorgung ab. Um diesem Sachverhalt zu begegnen, werden nicht nur komplexere Prognosealgorithmen, sondern auch eine verstärkte und zum Teil automatisierte Kommunikation zwischen Verteil- und Übertragungsnetzbetreibern, Erzeugern und Prognoseanbietern benötigt.


Bei all diesen Fragestellungen können Methoden des Maschinellen Lernens (ML) helfen, mit den wachsenden Datenmengen optimal umzugehen.

Im Rahmen verschiedener Forschungsprojekte wurde in den letzten Jahren der Frage nachgegangen, wie Prognosen den neuen Anforderungen an Genauigkeit, zeitlicher Auflösung und veränderten Rahmenbedingungen gerecht werden können, um die FEE optimal in das Energiesystem zu integrieren.

2. Prognosegüte und Ausgleichsenergiekosten: Direktvermarkterperspektive

Aus Sicht der Direktvermarkter ist die Ausgleichsenergie ein stark von Unsicherheit geprägter Kostenblock. Ausgleichsenergie ist die Energie, die für die Balance von Nachfrage und Erzeugung in Bilanzkreisen verwendet wird. Sie ist damit direkt mit der in einer Regelzone genutzten Regelenergie verbunden. Ausgleichsenergie wird benötigt, wenn der von einem Erzeuger (oder Verbraucher) beim Übertragungsnetzbetreiber angemeldete Fahrplan von der tatsächlichen Einspeisung (oder dem Verbrauch) abweicht. Die zum Ausgleich abgerufene Regelenergie wird dann über einen regelzonenübergreifenden Preis [6] in Form von Ausgleichsenergiekosten auf die Verursacher umgelegt. Die Ausgleichsenergiekosten können einen signifikanten Anteil der Gesamtkosten eines Direktvermarkters von Elektrizität stellen. Sie können dabei ein Vielfaches der fixen Kosten wie z. B. der Kosten zur Prognoseerstellung, der IT-Kosten, Handelskosten und Personalkosten betragen.

Das agentenbasierte Simulationsmodell AMIRIS [4], [5] befasst sich mit der Integration erneuerbarer Energien in die Strommärkte und analysiert dabei besonders den Einfluss regulatorischer Maßnahmen auf das Verhalten der Marktakteure. Prototypische Akteursgruppen werden in dem Modell als Agenten abgebildet. Analysen der Marktakteure bilden dabei die Grundlage der möglichst realitätsnahen Parametrisierung der Agenten. Ähnlich dem realen Marktgeschehen prognostizieren die Agenten ihre Erzeugung, handeln den Strom an der Strombörse, nutzen ggf. Förderinstrumente und müssen für fixe und variable Kosten aufkommen. Die Ausgleichsenergiekosten als unsicherer, aber signifikanter Bestandteil der variablen Kosten werden im Modell ebenfalls abgebildet.



ZSW

Frank Sehnke
frank.sehnke@zsw-bw.de

Anton Kaifel
anton.kaifel@zsw-bw.de

DLR

Dr. Marc Deissenroth
marc.deissenroth@dlr.de

Fraunhofer ISE

Elke Lorenz
elke.lorenz@ise.fraunhofer.de

Fraunhofer IWES

Dr. Jan Dobschinski
jan.dobschinski@iwes.fraunhofer.de

IZES

Dr. Uwe Klann
klann@izes.de

Die Akteure werden im Sinne eines wirtschaftlichen Handelns bestrebt sein, ihre Unsicherheiten in Bezug auf die Einspeiseprognose und somit ihre Ausgleichsenergiekosten, zu reduzieren. Mögliche Maßnahmen zur Verbesserung der Prognosegüte sind beispielsweise:

- Verbesserung der Prognosegenauigkeiten durch neue Algorithmen
- kurzzeitiger Handel, um auf Prognoseanpassungen zu reagieren (z. B. Teilnahme am Intraday Handel)
- Vergrößerung des Erzeugungsportfolios zur Reduktion statistischer Fehler
- Diversifikation des Erzeugungsportfolios

Die dargestellten Maßnahmen bedingen wiederum Kosten und erfordern den Aufbau neuen Know-Hows. Zwischen der angestrebten Kostenreduktion und den dafür anfallenden Aufwendungen gilt es eine Balance zu finden, mit der der Akteur weiterhin erfolgreich am Markt teilnehmen kann.

3. Prognosegüte und Integrationskosten: marktliche Perspektive

Aus Sicht der Strommärkte ist darauf zu verweisen, dass eine bessere Prognosegüte generell die Systemkosten des Elektrizitätssystems senkt, da Risiken reduziert werden. Für eine spezifischere Betrachtung aus marktlicher Sicht sind Wirkungen auf Investitionsentscheidungen und auf den Betrieb bestehender Anlagen zu unterscheiden.

Für Investitionsentscheidungen sind langjährige mittlere Ertragsprognosen notwendig. Dabei kann eine bessere Ertragsprognose, insbesondere für Windkraftanlagen zu einer Auswahl besserer Standorte und über geringere Risiken zu verringerten Kapitalkosten führen. Für eine bessere Integration von Neuanlagen ist aber v. a. eine bessere Prognose des zeitlichen Einspeisemusters einer potenziellen Anlage wichtig. Über dieses kann abgeschätzt werden, inwieweit die geplante Anlage aufgrund ihres zeitlichen Musters der Einspeisung überdurchschnittliche Erlöse erzielt. Sie kommen zustande, wenn die Einspeisung mit hohem Gewicht in Zeiten zu erwartender hoher Preise erfolgt. Zusammengefasst dürfte in der langfristigen Sicht eine bessere Prognose von Einspeisemustern die Systemintegration der FEE-Erzeugung verbessern.

Für die kurze Frist kann der Bestand an Anlagen als gegeben angenommen werden. Hierbei ist insbesondere der Day-ahead-Markt von Bedeutung. Mit dem Day-ahead-Markt hängen die Regelenergiemärkte sowie der Intraday-Markt zusammen: Für Betreiber

von Erzeugungsanlagen aber auch für Anbieter von Flexibilitäten stellen die möglichen Erlöse auf den jeweils anderen Märkten Opportunitätskosten für die Teilnahme auf einem dieser Märkte dar.

Gegenwärtig ist die Güte von FEE-Prognosen kurz vor Ende des Handels auf dem Intraday-Markt bereits sehr gut. Die Wirkung einer erhöhten Prognosegüte kann daher nur in dem veränderten Zusammenspiel dieser Märkte bestehen. Zum Beispiel kann sie den Bedarf an Regelenergie verringern. Gleichzeitig stehen dann die entsprechenden für Regelenergie nicht benötigten Flexibilitäten auf den anderen Märkten zur Verfügung. Besonders interessant wäre eine merkliche Verbesserung der Prognosegüte auf dem Day-ahead-Markt. Er würde dann weniger durch Risikoerwägungen bestimmt. Dies würde insbesondere dazu führen, dass die Netzflussberechnungen der Übertragungsnetzbetreiber (ÜNB) akkurater wären und die ÜNB mögliche Netzprobleme frühzeitig erkennen können. Zudem könnten Nachjustierungen der Einsatzplanung von Kraftwerken und Flexibilitäten, die mit einem Handel auf dem Intraday-Markt einhergehen, verringert werden.

4. Prognosen für den Netzbetrieb

Prognosen der Netzeinspeisung erneuerbarer Energien sind seit vielen Jahren unerlässlich für die tägliche Arbeit der deutschen Übertragungsnetzbetreiber (ÜNB). Diese verwenden Wind- und PV-Einspeiseprognosen für verschiedene Zeithorizonte und räumliche Aggregationen primär für Netzplanungsprozesse. Nicht nur aufgrund des steigenden Anteils an direkt vermarkteten EE-Strom, sondern auch aufgrund der kontinuierlich steigenden Installationszahlen von Windenergie- und PV-Anlagen und der damit einhergehenden Effekte auf die Netzbetriebsführung werden genauere Prognosen der physikalischen Netzeinspeisung immer wichtiger.

Bereits heute verwenden die ÜNB – sowie einige wenige Verteilnetzbetreiber (VNB) – netzknotenscharfe Prognosen zur vorausschauenden Lastflussberechnung. Diese basieren jedoch meist auf einfachen statischen Zuordnungen von Einzelanlagen, Parks oder Aggregationen dieser in Form von Planflächen zu einzelnen Netzknoten. In der Mehrzahl beruhen diese Zuordnungen auf einfachen Abstandsmetriken, wobei sich die Einflussgebiete der Netzknoten folglich durch Polygone beschreiben lassen.

Dieser Ansatz weist jedoch nicht zu vernachlässigende Fehlerquellen auf, da der Großteil der Windenergie- und PV-Anlagen in den Verteilnetzen eingeschlossen ist und die Dynamik der untergelagerten

Netze im Hinblick auf Netzschaltungen und resultierende Lastflüsse nicht in den Prognosemodellen berücksichtigt werden. Um dieser Herausforderung gerecht zu werden, müssen geeignete Informations- und Datenschnittstellen zwischen ÜNB und VNB aufgebaut werden, welche die notwendigen Informationen zeitnah austauschen (Energieinformationsnetze). Vorausschauende Lastflussberechnungen im Verteilnetz auf Basis von Einspeiseprognosen am Netzzugangspunkt ermöglichen dem VNB, die Planung seines Netzbetriebs zu optimieren. Andererseits kann er Informationen über die aktuelle Wirk- und Blindleistungsmenge je Netzverknüpfungspunkt mit zusätzlichen Informationen über die zukünftig zu erwartenden Mengen anreichern und dem ÜNB zur Verfügung stellen, welcher diese Informationen wiederum in seinen Netzberechnungen und Entscheidungsfindungsprozessen integriert.

In verschiedenen Forschungsprojekten am Fraunhofer IWES (EWeLiNE, SysDL2.0) wird derzeit daran gearbeitet, wie Informationen über wetterbedingte Prognoseunsicherheiten in automatisierte Prozesse zur vorausschauenden Lastflussberechnung integrieren werden können [1], [2], [3]. Nach aktuellem Kenntnisstand bietet sich hier eine Umsetzung von Szenario-Lastflussprognosen an, welche auf Szenario-Prognosen der Nachfrage und Erzeugung am Netzknoten basieren (siehe *Abbildung 1*).

Szenario-Prognosen der Wind- und PV-Einspeisung lassen sich bereits heute auf Basis von Ensemble-

Wetterprognosen mit nachgelagerter Kalibrierung in Form von Copula-Modellen erstellen. Die verschiedenen Ergebnisse der Lastflussprognosen können dann als Eintrittswahrscheinlichkeit bestimmter vorher zu definierender Netzzustände interpretiert werden. Anhand der Eintrittswahrscheinlichkeit lassen sich dann anschließende Maßnahmen wie Netzschaltung, Wartungsarbeiten an Netzbetriebsmitteln oder Redispatch zuverlässiger planen und umsetzen. Die Einspeisung vieler EE-Anlagen ist aber nicht mehr allein durch das Wetter bestimmt, sondern unterliegt diversen Einflussfaktoren, welche die derzeit eingesetzten Prognoseverfahren nicht explizit berücksichtigen. Dazu gehören:

- netzsicherheitsbedingte EE-Abregelungen
- marktgesteuerte Abregelungen durch Direktvermarkter
- PV-Eigenverbrauch
- Einsatz von Speichern
- Bereitstellung von Systemdienstleistungen durch EE-Anlagen
- Wartungsarbeiten
- Alterungsprozesse von Anlagen
- tageszeitabhängige Abregelungen aufgrund von Umweltbelastungen

Bereits heute haben die aufgeführten Faktoren einen spürbaren Einfluss auf die Genauigkeit von Verfahren zur Bestimmung der aktuell und zukünftig zu erwartenden EE-Einspeisung und führen grundlegend zu einem Anstieg der Prognoseunsicherheiten. Die Integration geeigneter und zeitnah verfügbarer Infor-




Abbildung 1
**Ergebnisinterpretation
 einer Szenario-Last-
 flussprognose**
 (Beispiel-Anwendungs-
 fall)

mationen sowie Modellierungsansätze der einzelnen Maßnahmen sind keinesfalls trivial und erfordern einen erhöhten Forschungsbedarf im Bereich der Prognosen für Energiesysteme.

5. Erweiterung von Datenquellen

In Zukunft müssen verschiedene Datenquellen weiterentwickelt und stärker eingebunden werden, um Prognosen zu verbessern.

Für die Systemintegration fluktuierender Solarenergie, sind Prognosen der Solarleistung nötig, die vom kleinen Hausspeicher bis zum Übertragungsnetz reichen. Die Anforderungen an Solarleistungsprognosen werden durch die jeweilige Anwendung bestimmt. Die benötigten räumlichen Skalen reichen dabei von einzelnen Gebäuden und Kraftwerken über Quartiere und Verteilnetze bis zum Übertragungsnetz, die zeitlichen Skalen umspannen wenige Minuten bis zu mehreren Tagen im Voraus. Für die verschiedenen Anwendungen mit den jeweiligen spezifischen Anforderungen in Bezug auf Vorhersagehorizont und räumlich-zeitlichen Auflösungen kommen unterschiedliche Datenquellen und Methoden zum Einsatz.

Solarstrahlungsvorhersagen bis zu einigen Tagen im Voraus werden auf Basis numerischer Wettermodelle (NWP) erstellt. Durch die oben beschriebenen Problematiken wird aber auch immer mehr Gewicht auf die sehr frühen Zeithorizonte (Minuten) gelegt.

Andere Informationsquellen können die Lücken hier schließen, z. B. Online-Erzeugungs-Daten, Sensoren vor Ort (Wolkenkameras, Long-range Lidar), Satellitendaten u. v. m. Für Vorhersagehorizonte bis zu einigen Stunden weisen Vorhersageverfahren auf Basis der Analyse von Wolkenzugvektoren aus Satellitenbildern eine höhere Genauigkeit auf als NWP-Strahlungsprognosen. Zur Vorhersage kleinskaliger Fluktuationen (~Minuten/~10 Meter) bis zu ca. 15 bis 30 Minuten im Voraus werden seit einigen Jahren Modelle auf Basis der Auswertung von Wolkenkameranadaten entwickelt. Insbesondere in stark variablen Situationen bieten diese einen Vorteil gegenüber Zeitreihenverfahren, die als Eingangsinformation ausschließlich aktuelle Messwerte nutzen.


Zur Optimierung und Kombination der verschiedenen Vorhersagemodelle werden statistische Verfahren eingesetzt. Hat man Zugriff auf eine lange Historie (≥ 1 Jahr) aller verwendeter Datenquellen, können die Daten durch künstliche neuronale Netze (KNN) kombiniert werden, um die Vorhersageleistung weiter zu steigern.

6. Rolle des „Maschinellen Lernens“/ „Deep Learnings“ für Prognosen

Im Bereich des Maschinellen Lernens (ML) hat sich in den letzten Jahren eine Methodik hervorgetan, welche Deep Learning (DL) genannt wird. Dies ist eine bestimmte Gruppe von KNN, die in mehreren

Abbildung 2

Verbesserte Prognosen durch maschinelles Lernen (1):
Differenz zwischen Prognose mit statistischer Methode der physikalischen ECMWF-Prognose (grün) und der Neuronalen Netz-Prognose (orange)






Abbildung 3

Verbesserte Prognosen durch maschinelles Lernen (2):

Differenz zwischen Neuronaler Netz-Prognose und Hierarchischem NN-System

Gebieten des Computersehens, der Sprachverarbeitung uvm. Ergebnisse erzielt hat, welche die menschliche Leistung übertreffen. Es hat sich gezeigt, dass diese Methodik ideal geeignet ist, um die wachsenden Datenmengen aus unterschiedlichen Datenquellen zu integrieren und zu einer optimierten Prognose im Bereich der FEE zu verwenden. So konnten Ertragsprognosen für die Bestimmung von Windenergieanlagenstandorten in ihrem Ertragsfehler gegenüber der besten heute von Gutachtern verwendeten Methode halbiert werden [7].

Der Einsatz von ML-Verfahren hat gezeigt, dass hierarchische KNN-Modelle in der Lage sind, Portfolio-Prognosefehler signifikant gegenüber dem Prognosefehler von statistischen Methoden zu senken (Abbildungen 2 & 3).

Sogenannte Convolutional Neural Networks (CNN) können genutzt werden, um direkt von den Bildern einer Wolkenkamera die momentane Einstrahlung am Standort oder die Erzeugung einer PV-Anlage zu berechnen und im Bereich von Minuten in die Zukunft vorher zu sagen. Auch der Zug von Wolkenfeldern auf Satellitenbildern oder Wolkenkameras kann mit CNNs vorhergesagt werden.

In der Vergangenheit hatten KNN noch zwei Nachteile: Erstens sind sie nur unter hohem Rechenaufwand zu trainieren. Doch durch die rapide Entwicklung von Grafik-Prozessoren in den letzten Jahren ist ihr Einsatz für Wind- und PV-Prognosen nun schnell und zuverlässig möglich.

Zweitens war unbekannt, wie die leistungsstärkeren tiefen Strukturen von tiefen neuronalen Netzen (DNN) zu trainieren sind. Dies wurde durch die neuen Methoden des DL beseitigt, so dass DNN die vorliegende hohe Komplexität der FEE-Prognosen abbilden können.

Ein weiterer Vorteil der ML-Verfahren aus dem DL-Bereich ist die automatische Merkmalsextraktion. Hierbei können die relevanten Eingangsparameter für die Lösung eines Problems automatisch ermittelt und gewichtet werden. Es ist oft schwer zu sagen, welche Knoten und Parameter eines NWP Modells zur guten Prognose z. B. eines Windparks beitragen. KNNs können während des Trainings diese Informationen bereitstellen und damit den Forschern – wie den Betreibern – tiefere Einblicke in die meteorologischen Zusammenhänge liefern.

Referenzen

- [1] J. Dobschinski, M. Siefert, Y.-M. Saint-Drenan, A. Braun, S. Vogt, A. Röpnack: „Development of innovative weather and power forecast models for the grid integration of weather dependent energy sources“, Proceedings of the WindAc conference, Cape Town, South Africa, November, 2016
- [2] M. Siefert, J. Dobschinski, S. Otterson, T. Kanefendt, K. Lundgren, D. Ernst, M. Zirkelbach, A. Bergmann-Dick: “Probabilistic wind power forecasts based on the COSMO-DE-EPS weather model“, Proceedings of the 13th International Workshop on Large-Scale Integration of Wind Power into Power Systems as well as on Transmission Networks for Offshore Wind Power Plants, 11-13 November 2014, Berlin, Germany, 2014
- [3] S. Wende-von Berg, N. Nornhorst, S. Gehler, E. Schneider, T. Pilz, K. Seidl, U. Zickler: “SysDL2.0 – Methoden und Anwendungen“, 14. Symposium Energieinnovation, 10. bis 12. Februar 2016
- [4] Nienhaus, K., Deissenroth, M. & Reeg, M., 2014. Policy instruments and market integration of renewables – an agent-based model analysis. In 14th IAEE European Conference – Energy challenge and environmental sustainability, Rome, Italy.
- [5] Reeg, M. et al., 2013. Weiterentwicklung eines agentenbasierten Simulationsmodells (AMIRIS) zur Untersuchung des Akteursverhaltens bei der Marktintegration von Strom aus erneuerbaren Energien unter verschiedenen Fördermechanismen, Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR). Available at: <http://elib.dlr.de/82808/>.
- [6] regelleistung.net, 2016. Ermittlung reBAP und Umgang mit Korrekturen. Available at: <https://www.regelleistung.net/ext/static/rebap>.
- [7] F. Sehnke, A. Strunk, M. Felder, J. Brombach, A. Kaifel, J. Meis: „Wind Power Resource Estimation with Deep Neural Networks“, Proceedings of the 23rd International Conference on Artificial Neural Networks, 10-13 September 2013, Sofia, Bulgaria