

Sachbericht

WindStore

Optimierte Systemintegration von Offshore-Windenergie mittels intelligenter Verknüpfung verschiedener Prognosekonzepte und vorausschauendem Management von verteilten Kaskadenspeichern

Dezember 2025

| | |
|-------------------|---|
| Autor: | Dr. Mathias Rafler |
| Berichtszeitraum: | 01.01.2024 - 30.11.2025 |
| Projektpartner: | Fraunhofer-Institut für Energiewirtschaft und Energiesystemtechnik (IEE) Deutsches Zentrum für Luft- und Raumfahrt (DLR), Institut für Vernetzte Energiesysteme (VE) SEtrade GmbH |
| Webseite: | https://www.iee.fraunhofer.de/de/projekte/suche/2024/windstore.html |

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Energie unter dem Förderkennzeichen 03EI1065C gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.

Gefördert durch:



Bundesministerium
für Wirtschaft
und Energie

aufgrund eines Beschlusses
des Deutschen Bundestages

WindStore: Optimierte Systemintegration von Offshore-Windenergie mittels intelligenter Verknüpfung verschiedener Prognosekonzepte und vorausschauendem Management von verteilten Kaskadenspeichern

Teilvorhaben: Skalenbasiertes Feature-Engineering und Prognose mit Deep-Learning

Abschlussbericht

| | |
|---|-----------|
| Einleitung | 4 |
| Kurzfassung | 4 |
| Aufgabenstellung | 4 |
| Wissenschaftlicher und technischer Stand | 5 |
| Wetterlagenklassifikation und meteorologische Mustererkennung | 5 |
| Neuronale Netze für meteorologische Felder und Energieprognosen | 6 |
| Planung und Ablauf | 6 |
| Erzielte Ergebnisse | 7 |
| Datenakquise und Datenaufbereitung | 7 |
| Feature-Engineering und Bestimmung großflächiger Phänomene | 9 |
| Zeitliche Entwicklung räumlicher Phänomene | 12 |
| Kombination mit Satellitendaten | 15 |
| Anwendung auf Windparks | 16 |
| Zusammenfassung der wichtigsten Ergebnisse | 17 |
| Bekanntgewordener Fortschritt von anderen Stellen | 18 |
| Verwertung | 18 |
| Voraussichtlicher Nutzen und Verwertbarkeit | 18 |
| Erfolgte oder geplante Veröffentlichung der Ergebnisse | 19 |
| Referenzen | 19 |

Einleitung

Kurzfassung

Ziel des Projekts ist die Entwicklung eines neuartigen Deep-Learning-Skalenmodells zur Prognose von Wetterlagen und deren Einsatz für die Optimierung von Ertragsprognosen für Offshore-Windparks. Hierbei werden großflächige meteorologische Muster mit langsamer Dynamik mit regionalen, schnelllebigen atmosphärischen Prozessen kombiniert. Grundlage bilden numerische Wettervorhersagen.

Durch die gemeinsame Auswertung dieser Daten auf unterschiedlichen räumlichen Skalen sollen die Identifikation, Vorhersage und Charakterisierung relevanter Wetterlagen verbessert werden. Die dabei gewonnenen repräsentativen Merkmale dienen sowohl der Wetterlagenklassifikation als auch der Weiterverwendung in Modellen zur Optimierung der Leistungsprognosen, insbesondere unter komplexen oder extremen Wetterbedingungen.

Aufgabenstellung

Das Teilvorhaben „Skalenbasiertes Feature-Engineering und Prognose mit Deep-Learning“ widmet sich der Ableitung und Nutzung multiskaliger meteorologischer Features für Wetterlagenklassifikationen und deren Vorhersage. Grundlage sind numerische Wettermodelle, darunter die Ensemblevorhersagen des WEPROG Multi-Scheme Ensemble Prognose System (MSEPS) sowie ICON-EU.

Zentrale Aufgaben sind:

1. Feature-Engineering: Identifikation groß- und mesoskaliger Muster aus meteorologischen Feldern, Reduktion hochdimensionaler Daten auf kompakte, interpretierbare Repräsentationen und Koppelung der Features verschiedener Skalen, sodass großräumige Strukturen mit langsamer Dynamik lokale, schnelllebige Prozesse einbetten.
2. Modellentwicklung: Aufbau und Anpassung hybrider RNN-CNN-Architekturen zur Vorhersage latenter Features und zeitlicher Entwicklungen, einschließlich Evaluierung von Encoder-Decoder-Strukturen, latenter Aggregationen und Optimierung der Hyperparameter.
3. Integration in Leistungsprognosen: Nutzung der erlernten Feature-Repräsentationen zur Verbesserung von Windparkleistungsprognosen und Quantifizierung der prognostischen Unsicherheiten, insbesondere unter Berücksichtigung Ensemblevorhersagen.
4. Methodische Evaluation: Analyse der zeitlichen Stabilität der identifizierten Wetterlagen, Konstruktion von Übergangsmatrizen sowie Vergleich mit etablierten objektiven Großwetterlagen des DWD.

Das Teilvorhaben schafft somit die methodische Grundlage für die Verbindung von großräumiger Wetterlagenklassifikation und energiewirtschaftlicher Prognoseoptimierung, wobei die Integration weiterer Datenquellen wie Satellitendaten und die Vorhersage komplexer Wetterlagen langfristig vorgesehen sind.

Wissenschaftlicher und technischer Stand

Wetterlagenklassifikation und meteorologische Mustererkennung

Die Klassifikation atmosphärischer Großwetterlagen ist ein etabliertes Werkzeug der synoptischen Meteorologie. Grundlage ist die Beobachtung, dass Wetterphänomene räumlich und zeitlich strukturiert auftreten: Großräumige Strömungsmuster weisen typischerweise eine höhere Persistenz auf als kleinräumige turbulente Prozesse, ohne jedoch eine vollständige Trennung der Skalen zu ermöglichen. Entsprechend existieren unterschiedliche Methoden zur Beschreibung und Gruppierung dieser Muster, jeweils angepasst an Zielstellung, Skala und verfügbare Daten.

Zur Identifikation synoptischer Großstrukturen werden häufig Dimensionsreduktionsverfahren wie die Hauptkomponentenanalyse (PCA) eingesetzt, insbesondere in Kombination mit Clustering-Methoden zur Bestimmung dominanter Variabilitätsmuster im Geopotentialfeld in mittleren Troposphärenniveaus, z.B. 500hPa. Solche Verfahren bilden die Basis für Regime-Studien und synoptische Musterklassifikationen.

Für die mesoskalige Einordnung standen bis zum Zeitpunkt der Antragstellung 2022 objektive Zirkulationsindizes wie die objektiven Großwetterlagen (OGWL) des Deutschen Wetterdienstes und die Lamb-Wettertypen zur Verfügung. Diese Methoden basieren klassisch auf Druckfeldern und diagnostischen Gradienten. Weiterentwicklungen, die

Windfeldgradienten oder Kombinationen meteorologischer Felder verwenden, waren zu diesem Zeitpunkt bereits in der Literatur beschrieben (Jones et al., 2012; Neal et al., 2016), jedoch vor allem für großräumige Anwendungen etabliert.

Für energiewirtschaftliche Fragestellungen existierten bereits erste Ansätze, synoptische Muster mit Erzeugungs- oder Nachfragevariablen zu kombinieren. Die sogenannten Energy Weather Regimes (EWR) wurden bis 2020 in mehreren Arbeiten beschrieben und stellten einen Ansatz dar, um meteorologische Muster mit großskaligen Einspeisecharakteristika zu verknüpfen (Grams et al., 2017; van der Wiel et al., 2019). Diese Arbeiten zeigten bereits, dass klassische synoptische Typisierungen für energiewirtschaftliche Anwendungen begrenzt sind und zusätzliche Strukturparameter benötigen.

Insgesamt war bis zum Zeitpunkt der Antragstellung ein breites Spektrum an groß- und mesoskaligen Klassifikationsmethoden verfügbar. Gleichzeitig bestand eine erkennbare Forschungslücke bei regional aufgelösten, flächenfokussierten Wetterlagentypen, die speziell auf Offshore-Anwendungen und die Modellierung lokaler Windfeldstrukturen ausgerichtet sind.

Neuronale Netze für meteorologische Felder und Energieprognosen

Bis zum Zeitpunkt der Antragstellung waren neuronale Netze für meteorologische Zeitreihenprognosen bereits gut etabliert, insbesondere im Kontext erneuerbarer Energien. Ein frühes Beispiel ist die Kombination aus AutoEncodern und LSTM-Netzen für Solarleistungsprognosen (Gensler et al., 2016).

Für die Modellierung räumlich-zeitlicher meteorologischer Felder standen seit 2015 ConvLSTM-Architekturen zur Verfügung, die räumliche Faltungsoperationen mit rekurrenten zeitlichen Strukturen verknüpfen (Shi et al., 2015). Diese Ansätze wurden bis zum Zeitpunkt der Antragstellung insbesondere im Niederschlags-Nowcasting eingesetzt.

Parallel existieren erste generische Methoden zur Kopplung räumlicher und zeitlicher Abhängigkeiten in Graphstrukturen, darunter Structural-RNN (Jain et al., 2016). Für die Windleistungsprognose selbst wurden neuronale Netze bereits in den 1990er-Jahren eingesetzt, etwa zur datengetriebenen Modellierung von Windparkleistungen (Kariniotakis et al., 1996). Neuere Untersuchungen zeigten zudem das Potential spatio-temporalen Informationen aus benachbarten Windparks für Kurzfristprognosen (Vogt et al., 2018).

Zusammenfassend war der Stand der Technik bis zum Zeitpunkt der Antragstellung geprägt durch:

- Gut etablierte, tiefe Sequenzmodelle für meteorologische Zeitreihen (LSTM, AutoEncoder).
- Frühe feldbasierte spatio-temporale Modelle (ConvLSTM).
- Konzeptionelle Architekturen für komplexe räumlich-zeitliche Abhängigkeiten (Structural-RNN).

Damit besteht ein Bedarf an Methoden, die sowohl räumliche Strukturmerkmale meteorologischer Felder gemeinsam mit ihrer zeitlichen Entwicklung modellieren und dabei auch großräumige Muster berücksichtigen. Gleichzeitig fehlen Ansätze, die solche skalenübergreifenden Informationen mit regionalen Wetterlagen kombinieren.

Planung und Ablauf

Zunächst wurden relevante historische meteorologische und Leistungsdaten aus verschiedenen Quellen gesammelt: MSEPS-Ensemble, ICON-EU und Leistungs- und Messdaten von Alpha Ventus. Die Aufbereitung erfolgte begleitend.

Darauf aufbauend wurden multiskalige Features für die Klassifikation abgeleitet und die zugehörigen meteorologischen Eigenschaften untersucht. Diese Features wurden anschließend zur Vorhersage in RNN-CNN-Netzwerken eingesetzt, um im weiteren Verlauf die Wetterlagen vorherzusagen sowie Verbesserungen der Vorhersagegenauigkeit zu ermöglichen.

Erzielte Ergebnisse

Datenakquise und Datenaufbereitung

Infrastruktur

Die Verarbeitung der meteorologischen und betrieblichen Daten stellte hohe Anforderungen an Speicherplatz und Datentransfer. Für den Analysezeitraum 2021–2023 mussten etwa 10 Terabyte an Roh- und abgeleiteten Daten vorgehalten werden. Aufgrund dieser Datenmengen war eine ausschließliche Verarbeitung auf lokalen Arbeitsplatzrechnern nicht möglich; insbesondere der verfügbare Plattenspeicher erwies sich als limitierender Faktor.

Zur Sicherstellung eines stabilen und zentralen Datenzugriffs wurde daher eine Cloud-basierte Infrastruktur auf Basis von Amazon Web Services (AWS) eingesetzt. Die Daten wurden in über einen projektinternen Account verwalteten S3-Buckets gespeichert. Da der Datentransfer zwischen AWS und lokalen Rechnern kosten- und zeitintensiv war, wurden spezifische Datenaufbereitungsroutinen entwickelt, um die zu übertragenden Datenmengen deutlich zu reduzieren.

ICON-EU

Als primäre meteorologische Datengrundlage wurde das operationelle Wettermodell ICON-EU des Deutschen Wetterdienstes (DWD) genutzt. Das Modell deckt den europäischen Raum ab und liefert Vorhersagen mit einem räumlichen Gitterabstand von $0,0625^\circ$. Pro Modelllauf standen mehrtägige Vorhersagen zur Verfügung; für die vorliegende Analyse wurden jeweils die ersten 48 Stunden des 0-Uhr-Laufs verwendet.

Die Rohdaten lagen im GRIB-Format vor und umfassten pro Tag etwa 1,8–2,4GB an Volumen. Im Jahr 2022 erfolgte eine Anpassung des DWD-Modells, bei der die Modellregion

und interne Parametrisierung geändert wurden; dies führte zu einer leichten Änderung der räumlichen Abdeckung. Zur effizienten Nutzung der Daten wurde ein mehrstufiger Aufbereitungsprozess implementiert. Nach dem Download erfolgte eine automatisierte Zerlegung der Daten in räumliche Patches von ca. 110×140 Gitterpunkten (insgesamt etwa 6×10 Patches pro Tag). Die resultierenden Einzeldateien wurden anschließend in einem S3-Bucket auf der AWS-Infrastruktur abgelegt, sodass pro Tag rund 60 Dateien entstanden. Parallel dazu wurden die gewünschten meteorologischen Variablen zusammengefasst, um redundante Transfers zu vermeiden.

Für die eigentliche Analyse wurden die Daten zusätzlich in zeitlichen Chunks (typischerweise monatlich oder quartalsweise) verarbeitet. Dieses Vorgehen reduzierte den Daten- und Transferaufwand deutlich und erlaubte eine stabile parallele Verarbeitung der ICON-EU-Daten auf den verfügbaren Systemen.

MSEPS

Als zweite meteorologische Datenquelle kam das MSEPS-Ensemblemodell des Unternehmens Weprog zum Einsatz. Das Modell basiert auf der Kombination mehrerer numerischer Vorhersageschemata und generiert 75 Ensemblemitglieder, die unterschiedliche physikalische und numerische Modellvarianten repräsentieren. Für den Analysezeitraum 2021–2023 standen vollständige Ensemblevorhersagen zur Verfügung.

Die Daten lagen als lokale Zeitreihen für den Windpark Alpha Ventus vor und dienten im Projekt insbesondere zur Erstellung der Basis-Leistungsprognosen. Zusätzlich wurden räumliche Zeitreihen bereitgestellt, die in einem rotierten geographischen Koordinatensystem definiert sind. Die Daten wurden in ihrer ursprünglichen Form verarbeitet, um zusätzliche Interpolationsschritte zu vermeiden.

Die MSEPS-Daten wurden auf der AWS-Infrastruktur abgelegt und dort in strukturierter Form vorgehalten. Aufgrund des Ensembleumfangs erfolgte die Verarbeitung vollständig automatisiert und parallelisiert, wobei alle 75 Ensemblemitglieder berücksichtigt wurden.

Objektive Großwetterlagen

Als zusätzliche meteorologische Referenz wurden die vom Deutschen Wetterdienst (DWD) bereitgestellten objektiven Großwetterlagen (GWL) herangezogen. Diese beruhen auf einem regelbasierten Klassifikationsverfahren, das täglich aus einem festen Satz großskaliger meteorologischer Variablen bestimmt wird. Grundlage bilden dabei unter anderem Windrichtung, relative Feuchte und Geopotential auf definierten Druckniveaus, jeweils aus dem 12-UTC-Modelllauf. Die resultierende Klassifikation gilt für ein Zeitfenster von 24 Stunden.

Die Berechnung erfolgt für ein vom DWD festgelegtes räumliches Referenzgebiet mit einer Gitterauflösung von etwa 55 km (31×30 Gitterpunkte), das den Bereich von ungefähr 41°N bis 56°N sowie $20\text{--}23^\circ\text{O}$ bis $0\text{--}3^\circ\text{W}$ umfasst. Damit ist die Klassifikation nicht spezifisch auf das Projektgebiet zugeschnitten, stellt jedoch eine etablierte großskalige Referenz für die synoptische Situation über Mitteleuropa dar.

Im Projekt wurden die objektiven Großwetterlagen zum Vergleich mit den abgeleiteten räumlichen Mustern genutzt.

Maschinendaten Alpha Ventus

Für die Analyse der lokalen Betriebs- und Leistungscharakteristika wurden SCADA-Daten des Offshore-Windparks Alpha Ventus genutzt. Der Park umfasst zwölf Windenergieanlagen, bestehend aus sechs REPower 5M und sechs Areva M5000 Anlagen. Die Daten wurden über das Bundesamt für Seeschifffahrt und Hydrographie (BSH) bezogen und lagen als 10-Minuten-Aggregate vor. Für den Zeitraum 2021 bis 31.10.2024 standen vollständige Daten für eine der REPower-Anlagen sowie alle Areva-Anlagen zur Verfügung.

Zur Datenaufbereitung wurden Leistungskennlinien aus internem Datenbestand herangezogen. Diese dienten sowohl der Qualitätskontrolle (Identifikation plausibler und unplausibler Leistungswerte) als auch der weiteren Modellierungsschritte. Bei den Areva-M5000-Anlagen zeigte sich eine deutliche Abweichung zwischen den offiziellen Leistungskennlinien und dem empirisch beobachteten Verhalten. Die gemessenen Daten ließen eine deutlich günstigere Leistungscharakteristik vermuten, was jedoch nicht abschließend geklärt werden konnte und auf nicht identifizierte Daten- oder Messunsicherheiten hindeutet.

Maschinendaten Baltic 1

Für das Projekt waren zusätzlich Maschinendaten des Windparks Baltic 1 als Referenzdatensatz vorgesehen, um die Ergebnisse aus Alpha Ventus mit einem weiteren Offshore-Park vergleichen zu können. Die entsprechenden Daten wurden jedoch seitens des Betreibers bislang nicht bereitgestellt. Eine Einbindung von Baltic 1 in die Analyse war daher nicht möglich.

Bestandsanlagen

Zur Einordnung des Windparks Alpha Ventus in den regionalen Anlagenkontext wurden Daten aus dem Marktstammdatenregister (MaStR) der Bundesnetzagentur herangezogen. Die Marktstammdaten lieferten strukturierte Informationen zu den umliegenden Offshore-Windparks und deren Turbinen, darunter insbesondere Anlagenname, Windparkzugehörigkeit, Turbinentyp, Nabenhöhe, Rotordurchmesser, installierte Leistung sowie die geographischen Positionen der einzelnen Anlagen.

Die Daten dienten dazu, die räumliche Bebauung in der Umgebung von Alpha Ventus systematisch zu erfassen und deren potenziellen Einfluss auf die Betriebs- und Leistungsdaten zu berücksichtigen. Insbesondere war dies für die Plausibilisierung der SCADA-Daten sowie für die später durchgeführten Wake-Berechnungen relevant, da die nachträgliche Errichtung angrenzender Windparks erhebliche Änderungen in den großräumigen Strömungsbedingungen bewirken kann.

Die Datenextraktion und Filterung erfolgte automatisiert, sodass das Marktstammdatenregister regelmäßig und reproduzierbar ausgewertet werden konnte.

Für Simulationen wurden Leistungskennlinien aus dem internen Datenbestand verwendet.

Feature-Engineering und Bestimmung großflächiger Phänomene

Aufbereitung ICON-EU

Siehe Datenaufbereitung.

Untersuchung lokaler Zeitreihen

Zur Exploration der lokalen meteorologischen Bedingungen wurden stündliche Zeitreihen aus MSEPS-Ensemblemitgliedern herangezogen. Analysiert wurden auf 100m Temperatur, Windgeschwindigkeit, spezifische Feuchte sowie auf 500hPa die Geopotentialhöhe. Die Daten wurden zur Vorverarbeitung als Mittelwerte aggregiert.

Die zeitliche Zerlegung erfolgte additiv in Trend, Saisonalität und Restkomponente. Ergänzend wurden Autokorrelationsfunktionen (ACF/PACF) der Komponenten berechnet, um typische zeitliche Skalen zu identifizieren.

Die Analyse lieferte nur begrenzte zusätzliche Erkenntnisse: Neben offensichtlichen saisonalen Effekten waren keine signifikanten Strukturen erkennbar, die Rückschlüsse auf großräumige Wetterlagen zuließen. Die Untersuchung bestätigte, dass lokale Zeitreihen für die Bestimmung großflächiger Phänomene nur eingeschränkt geeignet sind.

Basis-Leistungsprognosen

Für die Erstellung von Basis-Leistungsprognosen wurde ein intern genutztes Wake-Modell (Jensen) herangezogen, das auf meteorologischen Variablen basiert und die zeitliche Entwicklung der Leistung in stündlicher Auflösung für jede einzelne Windenergieanlage des Parks Alpha Ventus liefert. Zur Kalibrierung des Windfeldes wurden die lokalen MSEPS-Zeitserien verwendet. Die SCADA-Daten dienen ausschließlich zum Vergleich und zur Bewertung der Prognosegüte, fließen jedoch nicht in die Wake-Berechnungen ein.

Darüber hinaus wurden Leistungsprognoseensembles generiert, indem mehrere MSEPS-Mitglieder kombiniert und durch das Wake-Modell geführt wurden. Im Vergleich zu Prognosen auf Basis von Mittelwerten bietet diese Ensemble-berechnete Leistung nicht nur Verbesserungen der Prognosequalität, sondern liefert zusätzlich Informationen über die Verteilung der prognostizierten Leistung, was erste Erfahrungen mit Ensemble-basierten Vorhersagen ermöglichte.

Die Analyse lieferte eine erste Baseline für die Leistungsprognose einzelner Anlagen und zeigte die Möglichkeiten auf, mit Ensembleinformationen Unsicherheiten und Variabilitäten in der Prognose zu quantifizieren.

Feature-Engineering

Das Feature-Engineering verfolgte zwei zentrale Ziele: Erstens sollten die hochdimensionalen meteorologischen Felder in eine kompakte, clusteringfähige Form überführt werden, die eine stabilere und regional sensitivere Identifikation großräumiger

Phänomene ermöglicht. Zweitens sollten die Merkmalsrepräsentationen so gewählt werden, dass sie zugleich eine geeignete Grundlage für die späteren Leistungsprognosen bilden. Dazu waren sowohl eine Reduktion der Dimensionen als auch die Konstruktion aussagekräftiger Aggregationen von Geopotential- und Windfeldern erforderlich.

Methodisch orientierte sich das Vorgehen an der regelbasierten Konstruktion der objektiven Großwetterlagen: Die Aggregation erfolgte angepasst an die einzelnen Felder, wodurch eine dimensionsreduzierte, fachlich interpretierbare Repräsentation entstand.

Die meteorologischen Felder wurden hierzu in mehreren räumlichen Skalen analysiert:

1. Großskalige Struktur:
Aus dem Geopotential auf 500 hPa wurden Hauptkomponenten mittels PCA extrahiert, um synoptisch relevante Muster abzubilden. Die Dimensionsreduktion führte hierbei von ursprünglich rund 100 000 Dimensionen (Gitterpunkte × Variablen) auf wenige Hauptkomponenten. Ergänzend wurde Manifold Learning untersucht, das jedoch keine zusätzlichen Erkenntnisse gegenüber der PCA bot.
2. Mittlere Skala:
Zur Beschreibung der Druckverhältnisse wurden Zyklonalitätsfelder (500 hPa) für mehrere Vergleichsregionen berechnet. Diese Features erfassen Hoch- und Tiefdruckgebiete sowie deren relative Intensität und dienten als strukturelle Ergänzung zu den großskaligen Geopotentialmustern.
3. Kleinere Skala:
Als lokale meteorologische Komponente wurden die dominanten Windrichtungen auf 950 hPa extrahiert. Diese bilden dynamische Prozesse in bodennahen Schichten ab, die in der synoptischen Skalierung nicht vollständig enthalten sind.

Die Kombination dieser skalenübergreifenden Merkmale führte zu einer kompakten, interpretierbaren Repräsentation der Felder und bildete die Grundlage für das anschließende Clustering.

Clusterstrukturen

Ausgangspunkt der Analyse waren die aus den meteorologischen Feldern abgeleiteten und aggregierten Feature-Vektoren, die für jeden Zeitschritt eine kompakte Repräsentation der großräumigen Wettersituation lieferten. Ziel war es, im hochdimensionalen Phasenraum Häufungspunkte zu identifizieren, die wiederkehrende Muster abbilden und damit eine strukturierte Grundlage für die spätere Nutzung in Leistungsprognosen schaffen.

Zur Bestimmung solcher Muster wurden mehrere Clustering-Verfahren eingesetzt, darunter Agglomerative Clustering, K-Means und DBSCAN. Die Bewertung der Clusterqualität und die Auswahl der Clusterzahl erfolgte anhand des Silhouette Scores, des Davies-Bouldin-Index und des Calinski-Harabasz-Scores. Ergänzend wurden alle Clusterlösungen meteorologisch plausibilisiert. Auf Basis dieser Kriterien erwiesen sich insbesondere Agglomerative Clustering und K-Means als geeignet; Agglomerative Clustering lieferte zudem eine interpretierbare Struktur, die für die spätere Einordnung hilfreich war.

Die finale Lösung umfasste zwölf Cluster, die jeweils durch charakteristische Muster der Windrichtung, mittlerer Windgeschwindigkeit, Zyklonalität und großskaligen Druckverhältnisse geprägt sind. Unter anderem zeigten sich:

- zwei Cluster mit ausgeprägt niedriger mittlerer Windgeschwindigkeit um 5 - 6 m/s, darunter eines ohne dominante Windrichtung,
- zwei Cluster mit signifikant erhöhter mittlerer Windgeschwindigkeit um 17 - 19 m/s.

Für die Weiterverarbeitung wurden die Eigenschaften der Clustermittelpunkte in ein kompaktes Encoding überführt, das die eindeutige Kennzeichnung der jeweiligen Wettersituationen mithilfe ihrer Eigenschaften ermöglicht. Die nachstehende Tabelle listet die identifizierten Wetterlagen zusammen mit ihren wesentlichen Eigenschaften auf. Die Bezeichnung der Wetterlage enthält in der Reihenfolge die dominante Windrichtung bzw. X für keine ausgeprägte Windrichtung, die mittlere Windgeschwindigkeit unterteilt in hoch/mittel/niedrig, die Prägung durch Hoch- oder Tiefdruckgebiet sowie die Ausprägung der großräumigen Druckmuster jeweils unterteilt auf A-E.

| Wetterlage | Mittlere Windrichtung [°] | Mittlere Windgeschwindigkeit [m/s] | Zyklonalität [] | C0 [] | C1 [] |
|------------|---------------------------|------------------------------------|------------------|--------|--------|
| W-h-C-BC | 264 | 19,4 | 46,0 | -0,83 | -0,25 |
| WS-h-A-AC | 227 | 16,7 | -9,3 | -0,88 | -0,26 |
| E-h-C-EE | 78 | 13,7 | 10,3 | -0,01 | 0,41 |
| WN-m-A-CA | 287 | 12,8 | -22,4 | -0,62 | -0,57 |
| S-m-C-BE | 178 | 11,6 | 17,0 | -0,84 | 0,07 |
| W-m-C-CC | 283 | 10,1 | 19,7 | -0,78 | -0,27 |
| NW-m-A-EB | 334 | 10,1 | -8,5 | 0,00 | -0,40 |
| ES-m-O-CD | 130 | 7,4 | -3,5 | -0,80 | -0,05 |
| WS-m-A-AC | 229 | 7,3 | -10,1 | -0,84 | -0,29 |
| W-l-A-DA | 280 | 7,0 | -17,3 | -0,61 | -0,55 |
| EN-l-A-DB | 72 | 5,9 | -15,9 | -0,46 | -0,43 |
| X-l-O-CD | 287 | 4,8 | 3,5 | -0,77 | -0,18 |

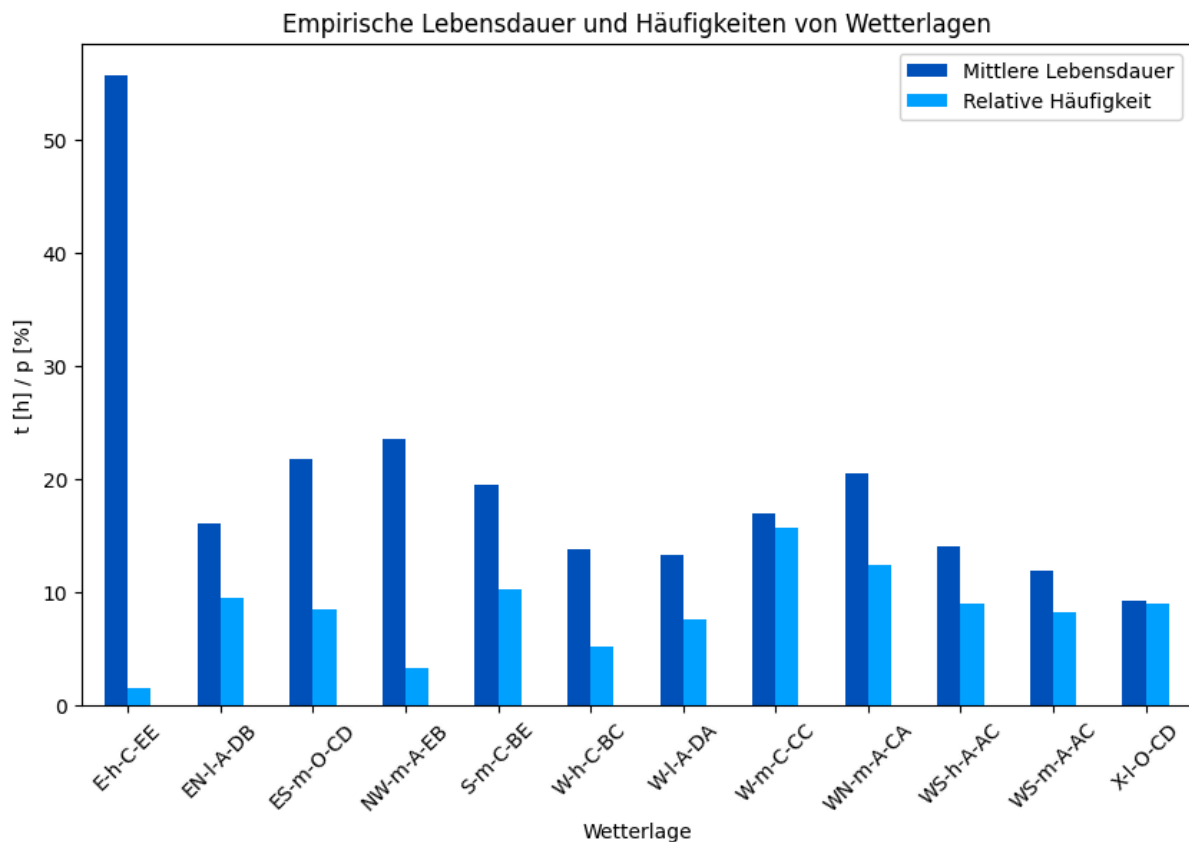
Zeitliche Entwicklung räumlicher Phänomene

Zeitliche Stabilität

Für die Analyse der zeitlichen Persistenz der gefundenen Muster wurde die stündliche Zeitreihe der zuvor identifizierten Wetterlagen (Cluster) ausgewertet. Ziel war es, die Stabilität der einzelnen Wetterlagen zu quantifizieren und ihre dynamischen Übergänge zu charakterisieren. Dazu wurden sowohl die Lebensdauer der Cluster als auch die Struktur der Übergänge zwischen ihnen untersucht.

Methodisch erfolgte zunächst die Identifikation zusammenhängender Sequenzen gleicher Clusterzugehörigkeit („Runs“). Für jedes Cluster wurde die Häufigkeitsverteilung der

Run-Längen berechnet und daraus die mittlere Lebensdauer bestimmt. Diese Kennzahl liefert eine direkte Aussage über die Stabilität der Wetterlagen.



Die obige Abbildung zeigt die mittlere Lebensdauer in Stunden sowie die Häufigkeit ihres Auftretens über die Zeit der jeweiligen Wetterlage.

Ergänzend wurde die Dynamik der Wetterlagen über die Schätzung einer Übergangsmatrix beschrieben. Die Matrix erfasst die empirischen Übergangswahrscheinlichkeiten zwischen allen Clustern und erlaubt damit Aussagen darüber, welche Wetterlagen bevorzugt aufeinander folgen und welche Übergänge selten oder praktisch ausgeschlossen sind.

Vergleich mit Großwetterlagen

Um die im Projekt identifizierten Cluster meteorologisch einzuordnen, wurde ein Vergleich mit den vom Deutschen Wetterdienst bereitgestellten objektiven Großwetterlagen (GWL) durchgeführt. Ziel war es, Gemeinsamkeiten und Unterschiede in der zeitlichen Dynamik und Struktur zwischen den projektinternen, regionalisierten Wetterlagen und den etablierten großskaligen Klassifikationen zu quantifizieren.

Methodisch erfolgte zunächst die Schätzung stündlicher Übergangsmatrizen für beide Systeme. Für die objektiven GWL wurde die 12-Uhr-Lage eines jeden Tages auf ein 24-Stunden-Fenster fortgeschrieben, um eine konsistente Basis für den Vergleich mit den stündlichen Projekt-Clustern zu schaffen. Zusätzlich wurden die GWL zur Verringerung der

Komplexität und zur besseren Vergleichbarkeit aggregiert, indem die Feuchtekomponente entfernt wurde, sodass der Fokus auf den primären Druck- und Strömungsmustern lag.

Die Analyse ergab deutliche Unterschiede zwischen den beiden Klassifikationen. Dies war erwartbar, da die Konstruktionen grundlegend unterschiedlich sind: Während die GWL synoptische Großmuster mit dominanten Hauptströmungen über Mitteleuropa abbilden, repräsentieren die im Projekt identifizierten Cluster stärker regional spezifische und differenzierte Wettersituationen.

Konstruktion der RNN-CNN

Für die Analyse der räumlich-zeitlichen Entwicklungen der meteorologischen Felder wurde eine hybride neuronale Netzarchitektur entwickelt, die Elemente der Bildverarbeitung und der Zeitreihenmodellierung kombiniert. Die Architektur folgt grundsätzlich dem Encoder-Decoder-Prinzip und ist darauf ausgelegt, sowohl die räumlichen Muster der Felder als auch deren zeitliche Dynamik abzubilden.

Encoder: Extraktion räumlich-zeitlicher Merkmale

Der Encoder verarbeitet die meteorologischen Felder in zwei Schritten:

1. Räumliche Verarbeitung (CNN-Komponenten): Die Felder werden als Bildfolgen interpretiert und über time-distributed Convolutional Layers verarbeitet. Dadurch werden für jeden Zeitschritt räumliche Strukturen wie synoptische Muster, Gradienten oder dominierende Strömungsrichtungen extrahiert. Diese Vorgehensweise ermöglicht es, Felder unterschiedlicher Auflösung konsistent einzubinden, ohne vollständige Interpolation auf ein einheitliches Gitter erzwingen zu müssen.
2. Zeitliche Verarbeitung (RNN-Komponenten): Die aus den CNN-Schichten erzeugten Feature-Maps werden anschließend über rekurrente Schichten zusammengeführt. Dadurch werden zeitliche Abhängigkeiten explizit modelliert und die Initialisierung des Decoders vorbereitet.

Diese Kombination erlaubt es, sowohl lokale als auch großskalige Muster synoptischer Prozesse zu erfassen und deren Entwicklung über mehrere Zeitschritte zu aggregieren.

Latente Aggregation

Im Projekt wurden mehrere Varianten zur Aggregation der räumlich-zeitlichen Merkmale untersucht. Unterschiedliche Konfigurationen der latenten Repräsentation (z. B. Projektionen in niedrigdimensionale Räume, getrennte vs. gemeinsame Latenzräume für verschiedene Variablen) ermöglichen es, den Einfluss meteorologisch relevanter Attribute gezielt zu variieren. Diese Flexibilität ist besonders hilfreich, da die meteorologischen Felder (z. B. Geopotential, Windrichtung, Zyklonalität) unterschiedliche räumliche Auflösungen und Strukturen aufweisen.

Decoder: Rekonstruktion des Zielraums

Der Decoder rekonstruiert abhängig vom Anwendungsfall unterschiedliche Zielgrößen:

1. Vektorielle Targets (z. B. Hauptkomponenten des 500-hPa-Geopotentials, Zyklonalitätsparameter, dominante Windrichtungen)
2. Bildtargets (z. B. rekonstruierte Felder oder Prognosen der räumlichen Muster)

Der initiale Zustand des Decoders wird durch den finalen Hidden State des Encoders bestimmt, wodurch die zeitliche Entwicklung der Felder explizit in die Rekonstruktion einfließt.

Einordnung gegenüber alternativen Architekturen

Alternative Architekturen wie Transformer-Modelle oder Graph Neural Networks wurden konzeptionell betrachtet, aber aufgrund projektinterner Rahmenbedingungen zunächst verworfen:

- Sie benötigen deutlich größere Trainingsdatensätze, um robuste Repräsentationen abzuleiten.
- Der Rechenaufwand ist im Vergleich zu RNN-CNN-Architekturen erheblich höher.
- Der Umgang mit unterschiedlichen räumlichen Auflösungen ist deutlich komplexer.

Die gewählte Encoder-Decoder-Architektur stellt daher einen methodisch sinnvollen Kompromiss zwischen Leistungsfähigkeit, Interpretierbarkeit und Ressourcenbedarf dar.

Funktionale Einschränkungen und aktuelle Erweiterungen

Die Architektur ist in der Lage, die Entwicklung eines einzelnen konstruierten Features zuverlässig vorherzusagen. Eine direkte Prognose der komplexen Wetterlagenklassifikation ist hingegen derzeit nicht sinnvoll, da hierfür konsistente Eingaben aus mehreren räumlichen Skalen erforderlich wären, die in der aktuellen Form noch nicht harmonisiert vorliegen.

Im Rahmen der Weiterentwicklung wurden daher zwei Erweiterungsrichtungen untersucht:

1. Multiobjektive Modelle: Kombination verschiedener Regionen bzw. verschiedener meteorologischer Skalen in einer Architektur, um die großräumige Struktur besser abzubilden.
2. Inklusion weiterer physikalischer Features: Integration zusätzlicher meteorologischer Variablen, die bisher nicht ausreichend repräsentiert waren, um die latente Struktur weiter zu stabilisieren.

Beide Richtungen befinden sich im aktiven Forschungsstand (Work in Progress).

Ergebnisse

Die Architektur wurde erfolgreich auf Bildfolgen meteorologischer Felder (z. B. Geopotential, dominante Windrichtungen) trainiert und konnte daraus sowohl:

- kompakte Vektorrepräsentationen (z. B. PCA-Komponenten, Zyklonalitätsmaße)
- rekonstruierte Felder oder Musterfolgen

ableiten.

Folgeschritte

Die nächste Phase besteht darin, die Architektur so zu erweitern, dass sie nicht nur Feature-Entwicklungen, sondern auch Übergänge der identifizierten Wetterlagen prognostizieren kann. Dies erfordert die Kombination der bisherigen Modelle mit ihren verschiedenen Eingangsgrößen. Modellarchitektonisch sind hier zwei Möglichkeiten zu evaluieren, einmal mit Verbindung im Encoder und gemeinsamer weiterer Verarbeitung und einmal mit Verbindung im Decoder und weitgehend eigener Verarbeitung der Eingabekanäle.

Kombination mit Satellitendaten

Die im Projekt geplante Einbindung von Satellitendaten wurde im Berichtszeitraum nicht operativ umgesetzt. Die Zusammenarbeit mit dem DLR beschränkte sich ausschließlich auf die fachliche Abstimmung zur Methodik der Best-Member-Selection. Dabei wurde geklärt, wie das DLR ASCAT-Satellitendaten nutzt, um aus dem 75-gliedrigen MSEPS-Ensemble diejenigen Modellläufe auszuwählen, die die beobachteten Windfelder am besten reproduzieren. Diese Abstimmungen dienten der Vorbereitung einer späteren Integration, ersetzen jedoch keine eigenen praktischen Arbeiten.

Eigene Arbeitsschritte – wie etwa der Vergleich des vollständigen Ensembles mit dem vom DLR ausgewählten Best-Member-Subset, die direkte Verarbeitung der Satellitendaten oder die Erweiterung der ML-Modelle auf ensemblefähige Eingaben – wurden im Projektzeitraum nicht durchgeführt. Die notwendige Datengrundlage war nicht gegeben: ASCAT ist kein geostationärer Satellit und liefert daher lediglich zeit- und raumweise Ausschnitte des Projektgebiets. Für eine operative Integration wären zusätzliche Vorarbeiten erforderlich gewesen, darunter eine Harmonisierung der Satellitendaten auf die ICON- bzw. MSEPS-Gitter und eine zeitliche Interpolation entlang der Überflugfrequenzen. Diese Arbeiten lagen außerhalb der im Projekt verfügbaren Ressourcen und Zeitfenster.

Durch die Abstimmungen mit dem DLR konnten jedoch die methodischen Voraussetzungen und potenziellen Einsatzmöglichkeiten der Best-Member-Selection präzisiert werden. Die eigentliche Umsetzung – sowohl die Nutzung der ausgewählten Ensemblemitglieder als auch die Evaluierung ihres Mehrwerts gegenüber dem vollständigen Ensemble – bleibt Gegenstand zukünftiger Arbeiten.

Anwendung auf Windparks

Ziel dieses Arbeitspakets war die Bewertung des potenziellen Mehrwerts der im Projekt entwickelten Wetterlagenklassifikation für die Leistungsprognosen des Offshore-Windparks Alpha Ventus. Die Anforderungen an die Analyse wurden verbundseitig abgestimmt und durch einen anderen Projektpartner erhoben; im vorliegenden Teilvorhaben lag der Fokus auf der methodischen Vorbereitung sowie der Untersuchung der grundlegenden Fragestellungen.

Zielsetzung

Die zentrale Frage bestand darin, ob und in welchem Umfang die neu identifizierten Wetterlagen – einschließlich ihrer zeitlichen Stabilität und räumlichen Charakteristika – die Güte bestehender Leistungsprognosen verbessern können. Hierbei standen insbesondere drei Aspekte im Vordergrund:

1. Ermittlung von Stärken und Schwächen bestehender Prognosemodelle in Abhängigkeit von Wetterlagen. Unterschiedliche meteorologische Muster können Prognosemodelle systematisch beeinflussen, beispielsweise durch variierende Turbulenzeigenschaften oder geänderte Strömungsregimes und damit eigener Wake-Ausbreitung.
2. Integration der neuen Features in die Leistungsprognosen. Die Frage war, ob die im Projekt entwickelten Merkmalsrepräsentationen – etwa PCA-Komponenten des

Geopotentials, Zyklonalitätsmaße oder dominante Windrichtungen – zusätzliche Information für Leistungsprognosen liefern.

3. Mehrwert durch Ensembleprognosen. Insbesondere die Nutzung der 75 Ensemblemitglieder des MSEPS-Modells eröffnet die Möglichkeit, Unsicherheiten explizit zu quantifizieren und witterungsspezifische Streuungen der Prognosegüte zu analysieren.

Methodischer Ansatz

Die methodische Konzeption zur Bewertung des Mehrwerts folgt drei komplementären Analysepfaden:

1. Berechnung von Metriken je Wetterlage. Für jede der identifizierten Wetterlagen werden Prognosegüte-Metriken berechnet, z.B. RMSE/MAE der Leistungsprognose, systematische Abweichungen, Streuung des Ensemble-Outputs, Robustheit der Prognose unter wechselnden atmosphärischen Regimen. Ziel ist die Beantwortung der Frage, ob bestimmte Wetterlagen konsistent mit höheren oder niedrigeren Prognosefehlern verbunden sind. Dies ermöglicht eine differenzierte Diagnose der Modellsensitivität gegenüber bestimmten Wettersituationen.
2. Erstellung von Leistungsprognosen mit den neuen Features. Die im Projekt entwickelten Features – sowohl vektorielle als auch flächenhafte – werden in bestehende Prognosemodelle integriert. Dabei entsteht ein direkter Vergleich:
 - a. Baseline-Prognose aus dem bisherigen Vorgehen.
 - b. Erweiterte Prognose mit den Wetterlagen oder konstruierten Variablen als zusätzlichen Features.Der Mehrwert zeigt sich dann in reduzierten Fehlern oder stabileren Prognosen, insbesondere in Situationen, die für Offshore-Anlagen meteorologisch anspruchsvoll sind (z.B. starke Scherung, schwache Druckgradienten, hohe Variabilität der Windrichtung).
3. Analyse des Mehrwerts durch Ensembleprognosen. Durch die Nutzung aller 75 MSEPS-Ensemblemitglieder lässt sich untersuchen:
 - a. Wie stark die Ensemblebreite von der Wetterlage abhängt.
 - b. Ob bestimmte Wetterlagen grundsätzlich höhere Unsicherheiten erzeugen.
 - c. Ob Ensemblemetriken wie Spread, Reliability und CRPS durch die neue Klassifikation interpretierbarer werden.

Aktueller Stand

Die methodische Grundlage zur Bewertung der Wetterlagen im Kontext der Leistungsprognosen wurde vollständig ausgearbeitet. Die praktische Umsetzung – insbesondere die systematische Berechnung der Wetterlagen-spezifischen Prognosemetriken und die Integration der neuen Features in die Leistungsmodelle – ist vorbereitet, wurde im Berichtszeitraum jedoch noch nicht ausgeführt.

Perspektive

Die Verknüpfung der Wetterlagen mit den Leistungsprognosen bietet ein erhebliches Potenzial durch:

- Die Identifikation systematischer Modellschwächen in bestimmten Wettersituationen.

- Verbesserte Ensembleinterpretation durch wetterlagenspezifische Unsicherheiten.
- Ein Fundament für ML-basierte oder hybride Leistungsmodelle, die explizit meteorologische Muster berücksichtigen.

Diese Perspektiven bleiben für zukünftige Arbeiten geöffnet.

Zusammenfassung der wichtigsten Ergebnisse

Im Rahmen des Projekts wurden Methoden entwickelt und getestet, um großräumige Wetterlagen zu identifizieren, ihre zeitliche Dynamik zu quantifizieren und sie für die Leistungsprognose von Offshore-Windparks nutzbar zu machen. Die wichtigsten Ergebnisse lassen sich wie folgt zusammenfassen:

1. Identifikation und Charakterisierung von Wetterlagen. Aus den aggregierten meteorologischen Features konnten im hochdimensionalen Phasenraum 12 Cluster identifiziert werden, die wiederkehrende großräumige Wettersituationen abbilden. Die Cluster zeichnen sich durch unterschiedliche Eigenschaften aus, wie mittlere Windgeschwindigkeit, dominante Windrichtung oder zyklonale Strukturen, und sind so meteorologisch konsistent interpretierbar. Analysen der zeitlichen Stabilität zeigten typische Lebensdauern der Wetterlagen und erlaubten eine quantitative Abschätzung der Dynamik von Übergängen zwischen den Lagen. Die Erstellung eines kompakten Encodings der Cluster ermöglicht eine konsistente Nutzung der Wetterlagen als Input für weiterführende Modellierungs- oder Prognoseverfahren.
2. Vergleich mit den objektiven Großwetterlagen des DWD. Die im Projekt entwickelten Wetterlagen unterscheiden sich deutlich von den OGWL, was erwartbar ist, da die Projektlagen regional spezifischer und stärker auf die Projektregion zugeschnitten sind, während die OGWL synoptische Großstrukturen abbilden. Durch Aggregation und Fortschreibung der DWD-Lagen auf 24 Stunden konnten die empirischen Unterschiede klar identifiziert werden. Dieser Vergleich zeigt, dass die identifizierten Wetterlagen einen Mehrwert in Bezug auf lokalere meteorologische Muster bieten, die in den etablierten synoptischen Klassifikationen nicht abgebildet werden.
3. Modellierungsansätze und Feature-Engineering. Mittels Feature-Engineering wurden hochdimensionale meteorologische Felder in kompakte, clusteringfähige Repräsentationen überführt, die zugleich als Input für Leistungsprognosen genutzt werden können. Eine kombinierte RNN-CNN-Architektur wurde entwickelt, die sowohl räumliche Muster (über Convolutional Layers) als auch zeitliche Dynamik (über rekurrente Layer) verarbeitet. Diese Architektur erlaubt zunächst die Vorhersage einzelner Features wie Zyklonalität oder PCA-Komponenten des Geopotentials. Eine direkte Vorhersage der Wetterlagen selbst ist aufgrund inkompatibler Inputs derzeit noch nicht umsetzbar. Die Methodik legt jedoch die Grundlage für zukünftige Erweiterungen, z.B. die Integration verschiedener Regionen, weiterer physikalisch relevanter Variablen oder die Nutzung ensemblebasierter Inputs.

Die im Projekt entwickelten Werkzeuge und Methoden schaffen eine Basis für die gezielte Nutzung großräumiger Wetterlagen in der Offshore-Leistungsprognose. Insbesondere die Kombination aus meteorologisch interpretierbaren Clustern, quantifizierter zeitlicher Dynamik und maschinell nutzbaren Features eröffnet Potenzial für genauere und robustere

Prognosen, die sowohl für bestehende als auch für zukünftige Offshore-Windparks relevant sind.

Bekanntgewordener Fortschritt von anderen Stellen

In den vergangenen Jahren wurden mehrere Arbeiten veröffentlicht, die den Zusammenhang zwischen großräumigen Wetterlagen, ihrer statistischen Beschreibung und ihrer Bedeutung für erneuerbare Energiesysteme vertiefen. Tedesco et al. (2023) analysieren die Kopplung von Kälte- und Schwachwindereignissen in Europa und zeigen, dass deren Auftretenswahrscheinlichkeiten stark von spezifischen winterlichen Wetterregimen beeinflusst werden. Die Studie nutzt ein Copula-basiertes Verfahren und bestätigt, dass die Einordnung meteorologischer Felder in Regimeklassen eine sinnvolle Grundlage für die Beschreibung sogenannter *compound events* liefert, die gleichzeitig Nachfrage- und die Einspeiseverhältnisse beeinflussen.

Die Notwendigkeit, über klassische Wetterregime hinaus weitere meteorologische und systembezogene Faktoren einzubeziehen, wird in Grochowicz et al. (2024) hervorgehoben. Auf Basis von Energiesystemmodellen wird gezeigt, dass Phasen erhöhter Systembelastung häufig mit großflächigen, persistenten Wetterlagen zusammenfallen, die durch klassische Klassifikationen nicht vollständig erfasst werden.

Neben diesen großskaligen Ansätzen weist die Analyse von Jose et al. (2024) auf die Relevanz mesoskaliger und lokaler Prozesse hin. Die Auswertung von Betriebsdaten eines Windparks zeigt, dass Niederschlag und kleinskalige Turbulenzstrukturen messbare Auswirkungen auf die Leistungsvariabilität haben und damit eine zusätzliche Unsicherheitsquelle darstellen, die in Prognosemodellen berücksichtigt werden sollte.

Parallel hierzu haben sich spatio-temporale Deep-Learning-Methoden weiterentwickelt. Modelle wie LSTMA_tU-Net (Geng et al., 2023) kombinieren Encoder-Decoder-Architekturen mit ConvLSTM-Einheiten und kanal-räumlichen Attention-Mechanismen und verbessern die Vorhersagequalität insbesondere für hochintensive Niederschlagsereignisse. Für großräumige meteorologische Felder zeigt Rahimi et al. (2024), dass U-Net-ConvLSTM-Modelle auch in globalen Anwendungen leistungsfähig sind, insbesondere in Verbindung mit physikalischen Steuergrößen aus numerischen Wettermodellen. Diese Entwicklungen verdeutlichen, dass hybride CNN-RNN-Architekturen heute sowohl für lokale hochaufgelöste Phänomene als auch für großskalige Felder eingesetzt werden können und damit eine direkte Relevanz für die Weiterentwicklung multiskaliger Wetterlagenklassifikationen und die anschließende Leistungsprognose besitzen.

Verwertung

Voraussichtlicher Nutzen und Verwertbarkeit

Die im Projekt entwickelten Methoden und Ergebnisse eröffnen sowohl praktische als auch wissenschaftliche Anwendungsfelder:

- Praxisrelevanz: Die Wetterlagenklassifikation liefert eine methodische Grundlage zur Verbesserung von Leistungsprognosen für Offshore-Windparks, indem sie meteorologisch anspruchsvolle Situationen identifiziert und die Vorhersagegüte in diesen Szenarien erhöht. Durch die Kombination mit ensemblebasierten Vorhersagesystemen lassen sich Unsicherheiten quantifizieren, was insbesondere für Netzbetreiber, Windparkbetreiber und Wetterdienste von direktem Nutzen ist. Die entwickelten Methoden bieten zudem die Möglichkeit, in bestehende operative Prognosesysteme integriert zu werden.
- Forschungsbeitrag: Das Projekt stellt ein methodisches Framework bereit, das Clustering, Feature-Engineering und RNN-CNN-Architekturen für meteorologische Anwendungen verbindet. Der Vergleich der identifizierten Projekt-Wetterlagen mit den etablierten objektiven Großwetterlagen des DWD liefert neue Erkenntnisse zur regionalen Spezifität von Wettersystemen und deren Vorhersagbarkeit. Die Ergebnisse legen zudem die Grundlage für weiterführende wissenschaftliche Arbeiten, z.B. zur Optimierung neuronaler Modelle für großräumige meteorologische Felder und zur Evaluation des Mehrwerts von Ensemblevorhersagen.
- Langfristige Verwertbarkeit: Die entwickelten Methoden, Workflows und Codes können direkt in Folgeprojekte oder kommerzielle Anwendungen überführt werden. Sie bieten eine Basis für ML-gestützte Wetter- und Leistungsprognosen sowie für die weitere Integration in hybride Prognosesysteme.

Erfolgte oder geplante Veröffentlichung der Ergebnisse

Im Rahmen des Projektes wurde bereits ein Posterbeitrag zur Wetterlagenklassifikation auf der 11. *International Conference on Timeseries and Forecasting (ITISE)* präsentiert. Der Beitrag trägt den Titel „Weather regimes in ICON data: Clustering and forecasting with RNN-CNN models“ und wurde vom 16.–18.07.2025 vorgestellt.

Darüber hinaus ist die Veröffentlichung eines wissenschaftlichen Fachartikels geplant, der die methodischen Erweiterungen sowie die Anwendung der entwickelten Wetterlagenklassifikation für Offshore-Leistungsprognosen beschreibt. Der Beitrag soll an die vorherige Arbeit (Emmerich et al, 2024) anknüpfen.

Referenzen

- [1] Dittmann, E., Barth, S., Müller-Westermeier, G., Lang, J. (1995): Objektive Wetterlagenklassifikation. Berichte des Deutschen Wetterdienstes Nr. 197, Offenbach am Main. <https://d-nb.info/108174233X/34>.

- [2] Zeitreihe der Objektiven Großwetterlagen
<https://www.dwd.de/DE/leistungen/wetterlagenklassifikation/wetterlagenklassifikation.html>
- [3] Jones, P. D., Hulme, M., & Briffa, K. R. (2012). A comparison of Lamb circulation types with an objective classification scheme. *International Journal of Climatology*, 13(6), 655–663. <https://doi.org/10.1002/joc.3370130606>
- [4] Neal, R., Fereday, D., Crocker, R., & Comer, R. E. (2016). A flexible approach to defining weather patterns and their application in weather forecasting over Europe. *Meteorological Applications*, 23(3), 389–400. <https://doi.org/10.1002/met.1563>
- [5] van der Wiel, K., Bloomfield, H. C., Lee, R. W., Stoop, L. P., Blackport, R., Screen, J. A., & Selten, F. M. (2019): The influence of weather regimes on European renewable energy production and demand. *Environmental Research Letters*, 14(9), 094010. <https://doi.org/10.1088/1748-9326/ab38d3>
- [6] Grams, C. M., Beerli, R., Pfenninger, S., Staffell, I., & Wernli, H. (2017): Balancing Europe’s wind-power output through spatial deployment informed by weather regimes. *Nature Climate Change*, 7, 557–562. <https://doi.org/10.1038/nclimate3338>
- [7] Tedesco, P., Lenkoski, A., Bloomfield, H. C. & Sillmann, J. (2023): *Gaussian copula modeling of extreme cold and weak-wind events over Europe conditioned on winter weather regimes*. *Environmental Research Letters*, 18(3), 034008. <https://doi.org/10.1088/1748-9326/acb6aa>
- [8] Grochowicz, A., van Greevenbroek, K. & Bloomfield, H. C. (2024): *Using power system modelling outputs to identify weather-induced extreme events in highly renewable systems*. *Environmental Research Letters*, 19(5), 054038. <https://doi.org/10.1088/1748-9326/ad374a>
- [9] Jose, J., Gires, A., Schnorenberger, E., Roustan, Y., Schertzer, D. & Tchiguirinskaia, I. (2024): *Multifractal analysis of wind turbine power and rainfall from an operational wind farm – Part 2: Joint analysis of available wind power and rain intensity*. *Nonlinear Processes in Geophysics*, 31, 603–624. <https://doi.org/10.5194/npg-31-603-2024>
- [10] Gensler, A., Henze, J., Sick, B., & Raabe, N. (2016). Deep Learning for Solar Power Forecasting—An Approach Using AutoEncoder and LSTM Neural Networks. 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 2858–2865. <https://doi.org/10.1109/SMC.2016.7844673>
- [11] Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., & Woo, W.-C. (2015). Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. NIPS 2015. : <https://papers.nips.cc/paper/2015/hash/07563a3fe3bbe7e3ba84431ad9d055af-Abstract.html>
- [12] Jain, A., Zamir, A. R., Savarese, S., & Saxena, A. (2016). Structural-RNN: Deep Learning on Spatio-Temporal Graphs. IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- [13] Kariniotakis, G., Stavrakakis, G. S., & Nogaret, E. F. (1996). Wind Power Forecasting Using Advanced Neural Networks Models. *IEEE Transactions on Energy Conversion*, 11(4), 762–767. <https://doi.org/10.1109/60.556376>
- [14] Vogt, S., & Bofinger, S. (2018). Benchmark of Spatio-temporal Shortest-Term Wind Power Forecast Models. 17th Wind Integration Workshop, Stockholm.

- [15] Geng, H., Ge, X., Xie, B., Min, J., & Zhuang, X. (2023). LSTMAtU-Net: A Precipitation Nowcasting Model Based on ECSA Module. *Sensors*, 23(13), 5785.
<https://doi.org/10.3390/s23135785>
- [16] Rahimi, R., Ravirathinam, P., Ebtehaj, A., Behrangi, A., Tan, J., & Kumar, V. (2024). Global precipitation nowcasting of IMERG satellite data using a U-Net ConvLSTM architecture. *Journal of Hydrometeorology*, 25(6), 947–963.
<https://doi.org/10.1175/JHM-D-23-0119.1>
- [17] Emmerich, F. & Abel, M. (2024). Identification of large-scale weather regimes over Europe using deep learning and PCA: A comparative study with the Großwetterlagen. Preprint.