



Bild: Radomír Novotný

# Fehler im Betrieb von Windenergieanlagen erkennen

## Von der Reaktion zur Prävention durch Zustandsüberwachung

50

dossier | it für evu

IN  
KÜRZE



**Florian Rehwald**

Die Windenergie hat in der Vergangenheit einen starken Wandel erlebt. Weg von robusten Stall-geregelten Anlagen, die ihre Leistung bei hohen Windgeschwindigkeiten passiv durch einen Strömungsabriss an stillstehenden Rotorblättern begrenzen, hin zu immer grösseren und komplexeren Pitch-geregelten Anlagen, bei denen die Leistung durch aktives Verdrehen der Rotorblätter begrenzt wird. Mit der zunehmenden Komplexität der Systeme ist auch die installierte Sensorik immer komplexer geworden. Wo früher einzelne Zählerwerte regelmässig überwacht wurden, werden heute oft mehre-

re Hundert Messwerte in Echtzeit überwacht und bereitgestellt.

Durch eine umfangreiche Messsensorik konnte sich die Instandhaltung von Windanlagen von einem korrektiven Ansatz hin zu einer zustandsorientierten Instandhaltung entwickeln. Dies machte den Betrieb effizienter und senkte die operativen Kosten. Auf der anderen Seite steigen mit der Zunahme der zu überwachenden Sensorik jedoch auch die Anforderungen an das Personal, das den Betrieb der Windparks überwacht.

Um das Monitoring im Betrieb zu ermöglichen, setzen klassische Energiesysteme auf

eine automatisierte Grenzwertüberwachung: Ein Lager läuft heiss, ein Motor zieht zu viel Strom, eine Spannung fällt ab, irgendein Wert überschreitet einen Grenzwert. Wenn der Alarm ausgelöst wird, ist die Störung oft schon da.

### Vorausschauende Diagnose

Neuartige Systeme wie der vom Fraunhofer IEE als Open-Source-Software (OSS) veröffentlichte EnergyFaultDetector verfolgen einen anderen Ansatz: Statt auf eindeutige Störungen zu warten, analysiert das System kontinuierlich Muster in den Betriebsdaten der Anlagen. Schon geringe Abweichungen vom «normalen» Verhalten – etwa ein schleichend sinkender Wirkungsgrad oder ungewöhnliche Temperaturverläufe – können Hinweise auf einen sich anbahnenden Fehler liefern.

Diese vorausschauende Perspektive bietet mehrere Vorteile:

- Frühe Warnung statt Ausfall: Instandhaltungsmassnahmen können geplant werden, bevor Schäden auftreten.
- Höhere Verfügbarkeit: Unerwartete Stillstände lassen sich reduzieren.
- Kosteneffizienz: Ersatzteile und Einsätze werden bedarfsgerecht statt rein intervallbasiert geplant.

Der EnergyFaultDetector macht diese Art der «präventiven Diagnostik» im Energiesektor niedrigschwellig nutzbar – und das ohne Lizenzkosten.

Die Digitalisierung des Energiesystems wird heute massgeblich von proprietären Lösungen geprägt. Monitoring- und Condition-Monitoring-Systeme sind oft eng mit bestimmten Herstellern, Anlagen oder Leitstellen verknüpft. Das erschwert den Vergleich, die Weiterentwicklung und den Austausch.

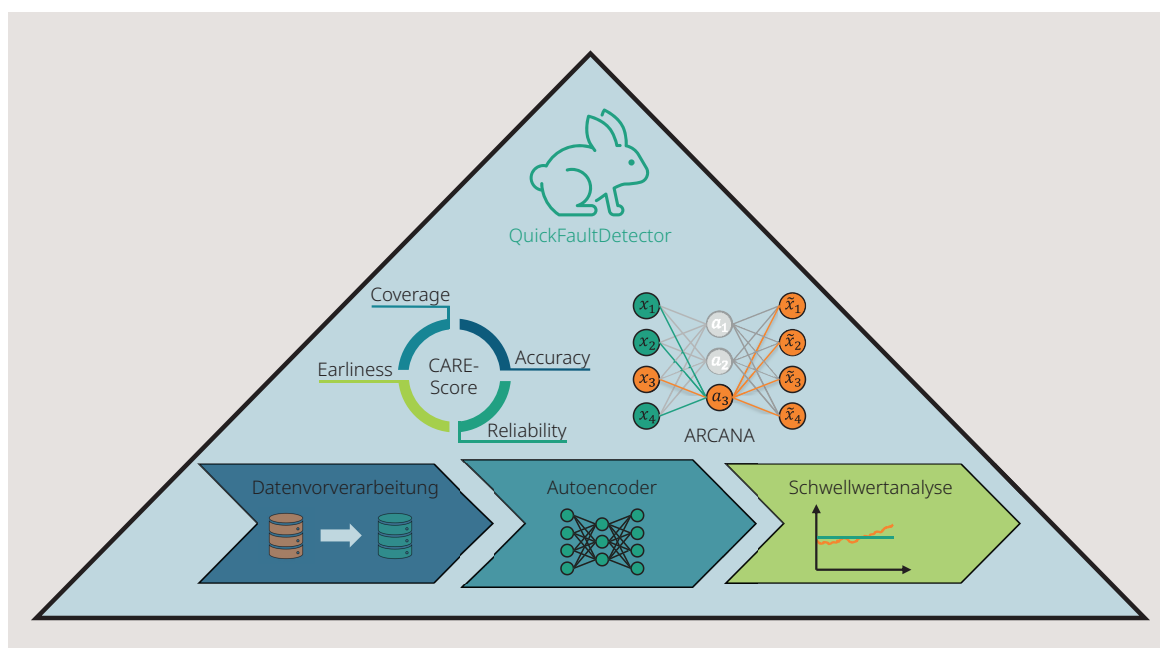
Hier setzt der EnergyFaultDetector an (Bild 1). Er ist als Open-Source-Projekt konzipiert und verfolgt folgende Kernziele:

- **Transparenz:** Algorithmen und Annahmen sind offen einsehbar und nachvollziehbar.
- **Vergleichbarkeit:** Verschiedene Verfahren zur Fehlererkennung können unter identischen Bedingungen getestet werden.
- **Übertragbarkeit:** Einmal entwickelte Methoden lassen sich auf unterschiedliche Anlagen und Datenquellen anwenden.
- **Nachvollziehbarkeit:** Der entwickelte Algorithmus liefert erklärbare Ergebnisse.

Damit wird die Fehlererkennung im Energiesystem zu einem «offenen Experimentierfeld»: Hochschulen, Forschungsinstitute, Netzbetreiber, Serviceunternehmen und Betreiber von Wind- und Solarparks können auf einer gemeinsamen Basis arbeiten – ohne sich zunächst auf eine proprietäre Plattform festlegen zu müssen.


Der EnergyFaultDetector verarbeitet kontinuierlich Betriebsdaten beispielsweise aus Leitsystemen, Zählern und Sensoren (z. B. Leistung, Temperaturen, Drücke, Schaltzustände) und bereitet diese in mehreren Schritten wie Plausibilitätsprüfungen, Ausreisser-Erkennung und Vereinheitlichung der Zeitauflösung auf. Aus historischen Daten erlernt das System das normale Anlagenverhalten in Form eines sogenannten Autoencoder-Modells, das beschreibt, wie sich die Anlage unter bestimmten Betriebs- und Umgebungsbedingungen verhalten sollte.

Im laufenden Betrieb vergleicht das System die aktuellen Messwerte mit den modellierten, erwarteten Werten, berechnet Abweichungen und prüft, ob diese statistischen Grenzen oder definierte Schwell-



**Bild 1** Kernelemente des EnergyFaultDetectors.

Bilder: Fraunhofer IEE



**Bild 2** Veranschaulichung eines Signalfehlers auf die Ausgangswerte des Autoencoder-Modells.

werte überschreiten. Auffällige Abweichungen werden als Anomalien oder Fehler klassifiziert.

Neben der Anomalieerkennung liefert das Framework auch die Möglichkeit, ein Fehlerfrühwarnsystem in Form eines überwachten Kritikalitätswertes zu konfigurieren. Der Kritikalitätswert steigt bei anhaltenden anormalen Zuständen und sinkt bei normalem Verhalten des überwachten Systems wieder. Auf Basis dieses Kritikalitätswertes lassen sich Grenzen festlegen, die beispielsweise für ein Ampelsystem oder Alarmmeldungen genutzt werden können.

### Vergleichbarkeit und Benchmarks

Neben den Algorithmen zur Anomalie bzw. Fehlerfrüherkennung stellt das Framework auch einen innovativen Ansatz zur Bewertung solcher Systeme bereit. Der integrierte CARE-Score dient zur gezielten Validierung von jeglicher Art von Frühwarnsystem und kann auch auf andere Ansätze angewandt

werden. Der Score kombiniert vier Metriken in einer und bewertet ein Früherkennungssystem hinsichtlich der Kategorien:

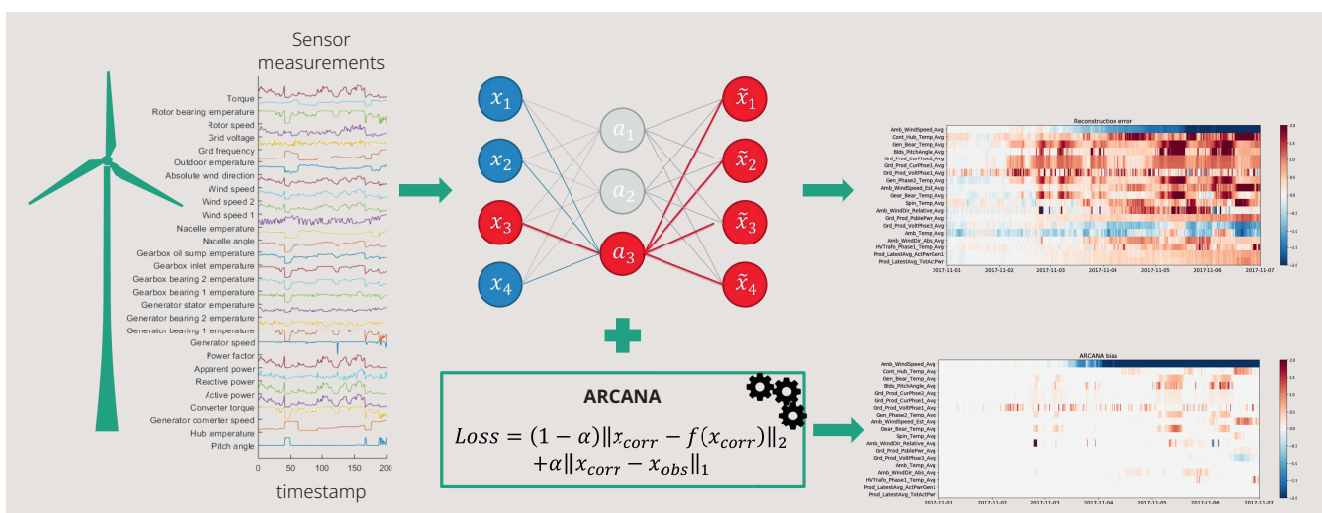
- **Coverage:** Korrekte Erkennung möglichst vieler Anomalien
- **Accuracy:** Erkennung von normalem Verhalten
- **Reliability:** Nur wenige Fehlalarme
- **Earliness:** Erkennung von Anomalien, bevor Fehler kritisch werden

### Ursachenanalyse

Zusätzlich zur Information, ob sich eine Anlage anormal verhält, liefert der EnergyFaultDetector auch die Information zur Ursache für diese Klassifikation mit. Diese Ursachenanalyse wird durch den Arcana-Algorithmus ermöglicht, der trotz Blackbox-Modell die fehlerverursachende Eingangsgröße identifizieren kann. Ein herkömmliches Autoencoder-Modell würde bei Abweichung einer Messgröße einen Rekonstruktionsfehler in allen Ausgangsgrößen hervorbringen (Bild 2).

Im Gegensatz dazu erlaubt der Arcana-Ansatz die gezielte Eingrenzung der fehlerverursachenden Größe. Dazu werden die Eingangsdaten mittels eines Optimierungsalgorithmus in zwei Teile aufgeteilt: einen Teil, der gut rekonstruiert wird, und den sogenannten Arcana-Bias, den «Rest» (Bild 3). Letzterer hat für die Eingangsgrößen einen grossen Wert, welche die detektierte Anomalie am ehesten erklären.

Im Betrieb liefert der Arcana-Ansatz sogenannte Arcana-Importances, welche dem Anteil einer Eingangsgröße am Fehlerbild entsprechen. Aufbauend auf diesen Werten lassen sich typische Muster bestimmten Fehlerbildern wie Sensorfehlern, Leistungsverlusten oder Regelungsproblemen zuordnen. Aufbauend darauf können weitere Verfahren zur Klassifizierung von speziellen Fehlermustern oder betroffenen Komponenten ermöglicht werden.



**Bild 3** Der Arcana-Algorithmus im Betrieb.

## Benchmark-Datensatz

Eine offene Software allein reicht nicht. Genauso wichtig ist ein Datensatz, mit dem sich Methoden in der Praxis bewähren müssen. Genau hier setzt der Benchmark-Datensatz CARE to Compare an, der im Paper «CARE to Compare: A Real-World Benchmark Dataset for Early Fault Detection in Wind Turbine Data» beschrieben wird. Der Datensatz enthält reale Betriebsdaten von Windenergieanlagen:

- Zeitreihen aus Scada-Systemen (z. B. Leistung, Windgeschwindigkeit, Temperaturen, Drücke).
- Langfristige Beobachtungszeiträume, in denen Anlagen unter sehr unterschiedlichen Betriebs- und Witterungsbedingungen laufen.
- Markierte Ereignisse, bei denen später Fehler oder Ausfälle aufgetreten sind.

Mit diesen Daten in Kombination mit dem CARE-Score lässt sich testen, ob ein Verfahren tatsächlich in der Lage ist, Auffälligkeiten früh zu erkennen – nicht nur im Labor, sondern unter realen Bedingungen.

Der Name ist Programm: CARE to Compare fordert dazu auf, verschiedene Algorithmen fair und transparent zu vergleichen. Der EnergyFaultDetector nutzt diese Möglichkeit und stellt Methoden bereit, die mit solchen Realdaten umgehen können.

## Open Source für neuen Bereich

Open Source kommt im Energiesektor bislang vor allem bei Tools zur Netzplanung oder Simulation zum Einsatz. Mit dem EnergyFaultDetector und

dem CARE-to-Compare-Datensatz rückt nun ein Bereich in den Fokus, der traditionell stark proprietär geprägt ist. Die Offenheit hat dabei mehrere Ebenen:

- Gesellschaftlich: Ein robustes, zuverlässiges Energiesystem erfordert Transparenz.
- Gemeinsam: Offene Werkzeuge können helfen, die Sicherheit und Effizienz erneuerbarer Energien schneller weiterzuentwickeln, ohne dass einzelne Marktakteure alle Schlüsseltechnologien kontrollieren.
- Wissenschaftlich: Forschende können ihre Algorithmen direkt auf Realdaten und einer gemeinsamen Referenzplattform erproben – und ihre Ergebnisse transparent vergleichbar machen.
- Industriell: Betreiber und Serviceunternehmen gewinnen Einblick in Methoden, die sonst oft als «Black Box» implementiert sind. Dies soll Vertrauen stärken und die Integration in bestehende Systeme erleichtern.

Damit fügt sich der EnergyFaultDetector in eine breitere Entwicklung ein: Die Energiewende wird nicht nur technologisch, sondern auch institutionell und digital organisiert – und offene Werkzeuge werden zu strategischen Bausteinen.

### Link

> [github.com/AEFDI/EnergyFaultDetector](https://github.com/AEFDI/EnergyFaultDetector)

### Autor

**Florian Rehwald** ist Product Owner EnergyFaultDetector.

> Fraunhofer IEE, 34117 Kassel, Deutschland

> [florian.rehwald@iee.fraunhofer.de](mailto:florian.rehwald@iee.fraunhofer.de)

# Détection des défaillances dans l'exploitation des éoliennes

## De la réaction à la prévention grâce à la surveillance de l'état

L'énergie éolienne a connu une profonde transformation au fil des années. On est passé des éoliennes robustes à régulation par décrochage (utilisant l'effet Stall), qui limitaient passivement leur puissance à des vitesses de vent élevées par un décrochage aérodynamique des pales fixes, à des machines plus complexes à pas variable (pitch control), dans lesquelles la puissance est limitée par une rotation active des pales. Grâce à une instrumentation de mesure étendue, la maintenance des éoliennes a pu évoluer d'une approche corrective vers une maintenance conditionnelle, fondée sur l'état.

Dans le monitoring en exploitation, les systèmes énergétiques classiques s'appuient sur

une surveillance automatisée des valeurs limites, qui déclenche généralement une alarme lors de l'apparition d'un dysfonctionnement. Les systèmes novateurs tels que l'EnergyFaultDetector, publié en open source par le Fraunhofer IEE, adoptent une approche différente: au lieu d'attendre des dysfonctionnements évidents, le système analyse en continu les schémas dans les données d'exploitation des machines. De légers écarts par rapport au comportement «normal» – comme une baisse progressive du rendement ou des courbes de température inhabituelles – peuvent déjà fournir des indices sur une défaillance imminente.