

ANWENDUNGSFALL PHOTOVOLTAIKANLAGEN

Predictive Maintenance mit Physics-Informed-Deep-Learning

» Die Fehlerdiagnose für Predictive-Maintenance-Anwendungen wird oft durch den Mangel an historischen Fehlerdaten erschwert. In einem laufenden Innosuisse-Projekt arbeitet das Smart Maintenance Team der ZHAW mit der Firma Fluence Energy zusammen, um diese Herausforderung mit hybriden Ansätzen zu überwinden, die physikalisches Wissen mit Deep-Learning-Algorithmen kombinieren.

Autoren: Lilach Goren Huber und Antonio Notaristefano

Der erste Schritt auf dem Weg zur vorausschauenden Instandhaltung besteht darin, abnormale Muster im Maschinenverhalten früh genug zu erkennen und deren Ursache zu diagnostizieren. Dies ermöglicht planbare Wartungseingriffe vor einem schweren Schaden und verhindert oft hohe Kosten und lange Ausfallzeiten.

Die Aufgabe, normales von abnormalem Maschinenverhalten zu unterscheiden, wird mit der Komplexität der Maschine und der Vielzahl möglicher Betriebszustände komplizierter. Eine digitale Schneidemaschine kann zum Beispiel für unterschiedliche

Materialien, Dicken und Schnittkonturen eingesetzt werden. Anhand der Sensordaten allein ist es nicht immer einfach festzustellen, ob eine der Schneidkomponenten beschädigt ist oder ob es sich lediglich um eine Änderung der Betriebsbedingungen handelt, die eine Änderung des Datenmusters verursacht hat.

Algorithmen des maschinellen Lernens können diese Aufgabe gut bewältigen, wenn sie entsprechend trainiert sind. Korrektes Training bedeutet, dass die Algorithmen Beispielen ausgesetzt werden sollten, die alle Betriebsbedingungen und idealerweise auch alle Fehlerarten abdecken. Unglücklicherweise ist das bei kommerziellen Anwendungen nicht immer realistisch. Fehler sind selten und von sehr unterschiedlicher Natur, und man kann nicht erwarten, dass man Zugang zu historischen Daten hat, die alle möglichen Fehlertypen aufzeichnen, die in einem bestimmten Maschinenflotten auftreten können.

VOM NORMALVERHALTENSMODELL ZU PHYSICS INFORMED MACHINE LEARNING

Für dieses Problem gibt es mehrere Lösungen. Die gebräuchlichste ist das sogenannte *Normalverhaltensmodell*. Algorithmen des maschinellen Lernens werden mit Daten aus völlig normalen (gesunden) Bedingungen trainiert – nachdem überprüft wurde, dass die Daten keine Fehler enthalten – und lernen so, das normale Verhalten der Maschine vorherzusagen. Während des Einsatzes wird die Vorhersage des Algorithmus mit den tatsächlichen Messwerten verglichen, und grosse Abweichungen werden als potenzielle Fehler erkannt. Solche Algorithmen beruhen in der Regel allein auf Sensordaten und werden daher als *datengetriebene Algorithmen* bezeichnet.

In seiner zukünftigen Version wird der Algorithmus in der Lage sein, die meisten der häufigen Fehler von netzgekoppelten Photovoltaikanlagen zu erkennen und zu diagnostizieren.



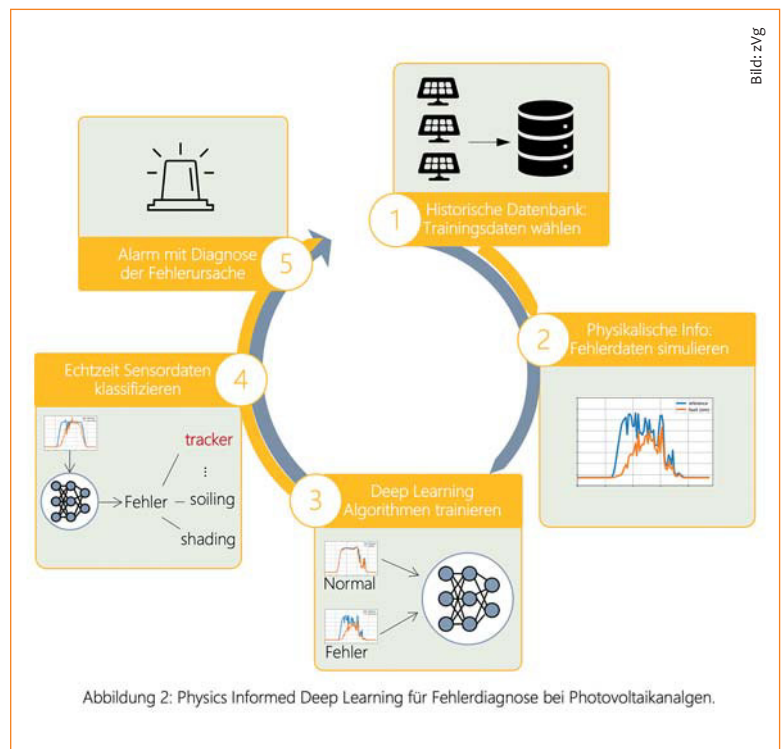
Bild: Zsuzsa Böke / Pixabay

In vielen Fällen können wir die Leistung dieser Algorithmen jedoch verbessern, indem wir das Wissen nutzen, das den technischen Experten des Unternehmens, zum Beispiel dem Servicepersonal, den Ingenieuren und Ingenieurinnen oder den Maschinenbedienern und -bedienerinnen, ohnehin zur Verfügung steht. Die Einbeziehung dieses physikalischen oder technischen Expertenwissens in Verbindung mit Sensordaten wird heutzutage unter dem Titel *hybride Ansätze* oder *Physics Informed Machine Learning* populär [1]. Die Einbeziehung von physikalischem Wissen in datengetriebene Algorithmen kann auf sehr unterschiedliche Weise erfolgen. In einigen Fällen werden neuronale Netzarchitekturen entworfen, die die physikalisch bedingten Einschränkungen einbeziehen. Ein anderer Ansatz besteht darin, das physikalische Wissen zu nutzen, um die Trainingsdaten anzureichern oder zu erweitern – zum Beispiel, um synthetische Fehlerdaten aus Daten des Normalzustands (gesunde Daten) zu generieren.

FEHLERDIAGNOSE BEI KOMMERZIELLEN PHOTOVOLTAIKANLAGEN

In unserem derzeitigen Forschungsprojekt wenden wir den letztgenannten hybriden Ansatz zur Fehlerdiagnose bei kommerziellen Photovoltaikanlagen an. Aus den historischen Daten der Anlagensensoren extrahieren wir Tagesprofile der erzeugten Leistung unter verschiedenen normalen Bedingungen, bei denen kein fehlerhaftes Verhalten beobachtet wurde. Anschliessend entwickeln wir ein physikalisches Modell für verschiedene häufige Fehler der Anlagenkomponenten. Dies ermöglicht es uns, die Tagesprofile auf eine physikalisch sinnvolle Weise zu verfälschen, die einem bestimmten Fehlertyp entspricht. Ein Beispiel für einen häufigen Fehler in Photovoltaikanlagen ist ein Tracker-Fehler [2]. Bei den Tracker-Systemen handelt es sich um bewegliche Teile, auf denen mehrere Stränge von Solarmodulen montiert sind. Die Tracker dienen dazu, die Paneele zur Sonne auszurichten, um die Energieaufnahme zu maximieren, wenn die Sonne über den Himmel wandert. Eine häufige Störung tritt auf, wenn einer der Tracker in einer bestimmten Position festsetzt und dadurch die Energieproduktion der darauf montierten Paneele verringert. Mit Hilfe eines physikalischen Modells der Bewegung der Tracker-Systeme können wir verschiedene Fehlerszenarien simulieren und fehlerhafte Tagesprofile der erzeugten Energie für bestimmte Solarmodule erstellen. Das Modell wird mit gesunden Daten aus dem Zustandsüberwachungssystem der Solaranlage gespeist (Schritt 1 in Abbildung 2) und simuliert Daten, die fehlerhaften Komponenten entsprechen (Schritt 2).

Die simulierten Daten werden zusammen mit den echten Betriebsdaten während der gesunden Perioden als Eingabe für ein tiefes neuronales Netz (NN)



verwendet. Das NN wird trainiert, um gesunde von fehlerhaften Profilen zu unterscheiden (Schritt 3). Die Ergebnisse zeigen, dass ein auf diese Weise trainiertes NN in der Lage ist, Tracker-Fehler in ungesenen Betriebsdaten zu erkennen und sie von gesunden Daten oder von anderen Arten von Fehlerdaten zu unterscheiden (Schritt 4). Auf diese Weise löst der Algorithmus einen Alarm aus, sobald ein abnormales Verhalten festgestellt wird, und liefert darüber hinaus eine Diagnose der Fehlerursache. In seiner zukünftigen Version wird der Algorithmus in der Lage sein, die meisten der häufigen Fehler von netzgekoppelten Photovoltaikanlagen zu erkennen und zu diagnostizieren.

Der Algorithmus wird derzeit getestet und in die Software der Firma Fluence Energy LLC als Teil des Moduls «Predictive Maintenance» für Photovoltaik-Kraftwerke implementiert. Diese Forschung wird von der Innosuisse – Schweizerischen Agentur für Innovationsförderung unter der Förderungsnummer 55018.1 IP-ICT finanziert.



REFERENZEN

1. Karniadakis, George Em, et al. «Physics-informed machine learning.» *Nature Reviews Physics* 3.6 (2021): 422-440
2. Mellit, Adel, Giuseppe Marco Tina, and Soteris A. Kalogirou. «Fault detection and diagnosis methods for photovoltaic systems: A review.» *Renewable and Sustainable Energy Reviews* 91 (2018): 1-17



Dr. Lilach Goren Huber
Projektleiterin
Smart Maintenance Team,
School of Engineering, ZHAW.
Leiterin der Smart Maintenance
Expert Group der Data-Innovation
Alliance.



Antonio Notaristefano
Dir. Engineering and Data Science,
Fluence Energy LLC.