

Einsatz von automatischer Datenanalyse zur Prozessüberwachung

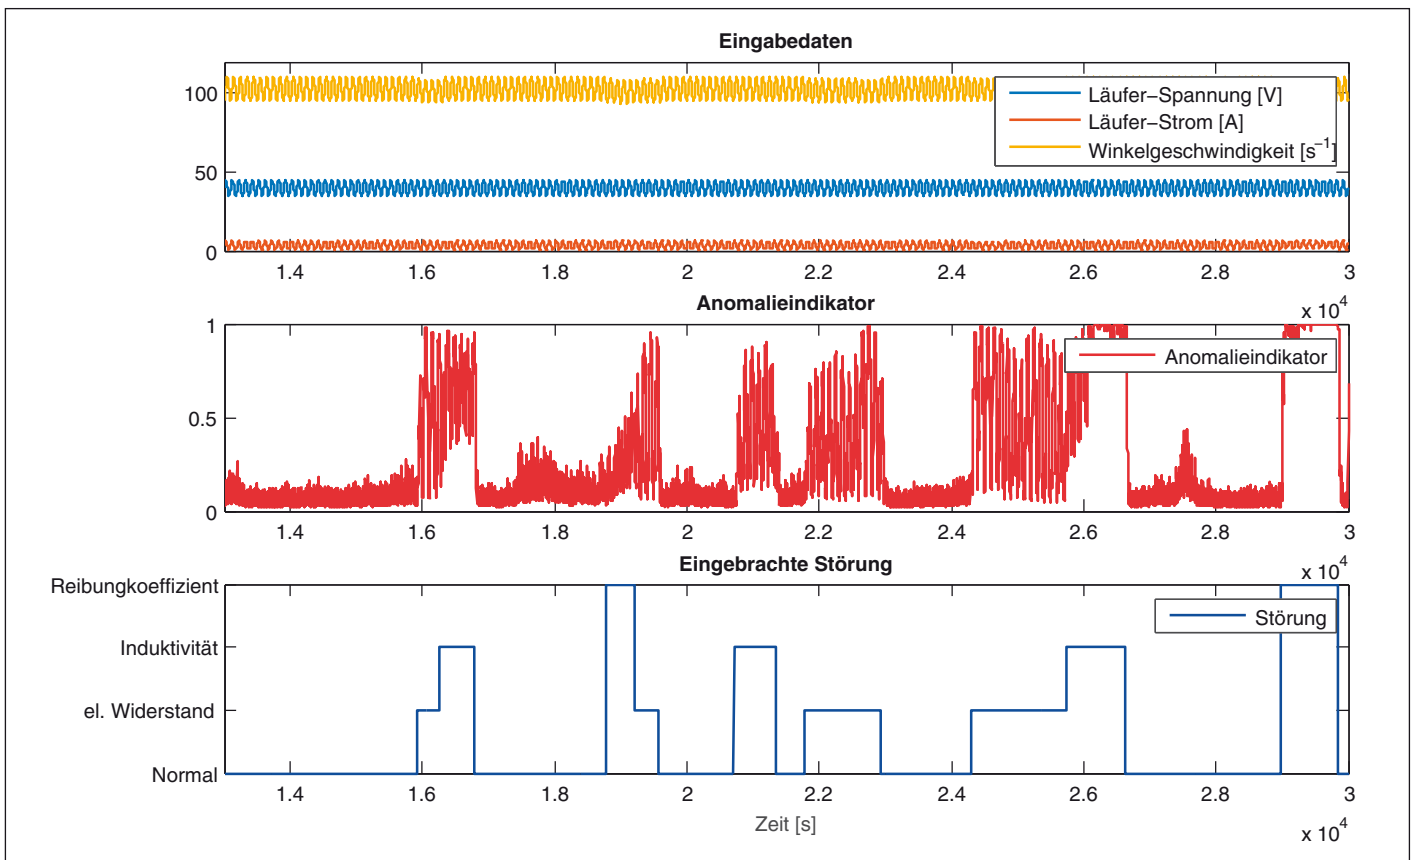


Bild 1: Beispiel „Anomalie-Erkennung bei einem Gleichstrommotor“

Durch den verstärkten Einsatz von Sensoren bei der Überwachung und Bewertung technischer Prozesse fallen in immer kürzeren Zeitabschnitten immer mehr Messdaten an. Durch diese große Zahl an Daten stellt sich die Herausforderung mit dem Umgang und vor allem mit der Auswertung der Daten. Ein relativ neuer Ansatz zur Überwachung und Beobachtung von Prozessen sind Algorithmen zum Verarbeiten von Datenströmen in Echtzeit, die sog. Stream Analytics, bei der die anfallenden Messdaten direkt verarbeitet werden. Hier finden Verfahren der automatischen Datenanalyse aus dem Bereich des maschinellen Lernens Anwendung. Mit diesem Big-Data-Ansatz lassen sich auf Basis von gelernten Modellen zeitliche Veränderungen und Abweichungen vom Normalverhalten eines Industrieprozesses zeitnah detektieren und verfolgen.

Eine Besonderheit dieser Algorithmen ist, dass das Normalverhalten

und bekannte Fehlerarten direkt aus den Messdaten gelernt werden können, ohne explizit von einem Experten ein Modell erstellen zu müssen. Dies ist mittlerweile auch vollautomatisch durch On-Line-Algorithmen im laufenden Betrieb möglich. Auf Basis des gelernten Modells können Ausreißer und Anomalien frühzeitig erkannt werden – und zwar weitgehend unabhängig von der Art der Sensordaten. Da durch diese Selbstkonfiguration das exakte Prozessverhalten nicht explizit modelliert werden muss, vereinfacht sich die Konfiguration der Überwachung komplexer, dynamischer Prozesse. Zudem lassen sich kurzzeitige Ausreißer kompensieren, genaue Prognosen generieren und zu erwartende, ungestörte Ergebnisse an das Leitsystem übermitteln.

Die automatische Datenanalyse


lässt sich somit für die permanente Überwachung der korrekten

Funktionalität, die Fehlersuche, das frühzeitige Erkennen von drohenden Störungen und insbesondere die Diagnose von Maschinen und Anlagen nutzen. Ein Anwendungsszenario ist z.B. die Beobachtung und Überwachung eines Elektrischen Antriebs. Hier lassen sich nach einer kurzen Lernphase unterschiedliche Störungen frühzeitig erkennen und entsprechende Wartungsmaßnahmen rechtzeitig einleiten.

Flexible Algorithmen sind notwendig

Da die Messdaten von sehr unterschiedlichen Quellen und Systemen stammen können, müssen die Algorithmen entsprechend flexibel sein. Für die Erkennung von Anomalien können die Algorithmen künstliche neuronale Netze oder Deep-Learning-Ansätze verwenden, die es ermöglichen, relevante Merkmale und Information aus umfangreichem Datenmaterial herauszufiltern.

Autoren:



Vesa Klumpp, Frederik Beutler, Geschäftsführer Knowtion UG – Spezialist für Sensorfusion und automatische Datenanalyse




Bild 2: Beispiel „Anomalie-Erkennung bei einer Abfüllanlage“

Durch diese Extraktion lassen sich große Datenmengen auf wesentliche, charakteristische Merkmale reduzieren. Unter Berücksichtigung des zeitlichen Zusammenhangs passt sich die Komplexität des Modells adaptiv an die vorhandenen Daten an. Mittels einer auf Wahrscheinlichkeiten basierenden Modellbeschreibung ist es möglich, einen Anomalieindikator zu definieren, der charakterisiert, wie gut die Messdaten zu dem gelernten Normalverhalten passt. Das Überschreiten des Anomalieindikators über einen vorher definierten Schwellenwert bedeutet, dass die Messdaten nicht zum vorher gelernten Modell passten und es sich somit um eine Anomalie beziehungsweise eine Störung im unterlagerten Prozess handelt.

Beispiel „Anomalie-Erkennung bei einem Gleichstrommotor“

In diesem Beispiel werden Störungen in einen Gleichstrommotor eingebracht und anhand von Messungen, die nicht direkt auf die Stö-

rung schließen lassen, erkannt. Gemessen werden die Spannung und Stromstärke am Läufer sowie dessen Winkelgeschwindigkeit. Es werden drei Arten von Störungen auf den Läufer aufgebracht: Diese Störungen umfassen eine Veränderung des Reibungskoeffizienten, der Induktivität und des elektrischen Widerstands des Läufers. Die jeweiligen Störungen sind in im unteren Teil „Eingabedaten“ in Bild 1 dargestellt. Im oberen Teil „Eingabedaten“ der Bild 2 sind die gemessenen Größen dargestellt. Diese Messdaten sind nicht „glatt“, sie unterliegen normalen mechanischen und elektrischen Effekten des Gleichstrommotors sowie den eingebrachten Störungen. Wie zu erkennen ist, verändern die eingebrachten Störungen die gemessenen Daten nur in sehr geringem Umfang.

Für die Anomalie-Erkennung wird zunächst der Normalzustand aus den Eingabedaten gelernt. Anschließend werden die gestörten Eingabedaten in den Algorithmus zur Anomalie-Erkennung übergeben. Das Ergebnis des Algorithmus ist im Teil „Anomalieindikator“ von Bild 1 dar-

gestellt. Es ist zu erkennen, dass bei einer Störung der Anomalieindikator ansteigt. Sobald der Schwellenwert 0,5 überschritten ist, gilt die Anomalie als erkannt.

Beispiel „Anomalie-Erkennung bei einer Abfüllanlage“

In diesem Beispiel werden Störungen an einer Abfüllanlage erkannt. Die Abfüllanlage wird mit mehreren Sensoren überwacht, die Größen wie Füllstand, Massenstrom oder Ventilöffnung erfassen. Im oberen Teil „Eingabedaten“ von Bild 2 sind Werte von fünf Sensoren dargestellt, die als Eingabegrößen für die Verarbeitung dienen. Hier lässt sich gut ein zyklischer Prozess mit einer Periode von etwa 300 Sekunden erkennen. Im unteren Teil „Anomalie-Indikator“ auf Bild 2 ist der berechnete Anomalie-Indikator abgebildet.

Es werden mehrere fehlerfreie Zyklen des Abfüllprozesses verwendet um ein Modell des Normalverhaltens zu lernen. Nun werden Störungen in den Abfüllprozess eingebracht. Es ist zu erkennen, dass der Abfall bei Sensor 2

(orange) bei Sekunde 690, der kurze Anstieg bei Sensor 3 (gelb) bei Sekunde 820 und das Ausbleiben des Anstiegs bei Sensor 4 (violett) bei Sekunde 1150 zuverlässig erkannt werden.

Welcher Nutzen für die Überwachung von Anlagen ergibt sich nun konkret aus diesem Ansatz?

Zum einen können Anwender Abweichungen und Anomalien durch die permanente Online-Überwachung durch Algorithmen früher und umfassender erkennen und Fehlentwicklungen bereits im Ansatz verhindern. Prozesse zur Qualitätssicherung lassen sich ständig verbessern und effizienter gestalten - sowohl in der Entwicklung als auch im Betrieb, beim Test oder bei der Wartung. Der hohe Automatisierungsgrad sorgt dafür, dass sich auch komplexe Messbewertungen mit geringem Ressourcen- und Personalaufwand durchführen lassen.