

Analyse, Erstellung und Umsetzung von Predictive Maintenance in der Fertigung am Beispiel einer Brandschutzanlage

Andre Wohnsland, Lisa Fischer, Prof. Dr. Andreas Thümmel, Prof. Dr. Markus Döhring

Hochschule Darmstadt – Fachbereiche Informatik & Mathe und Naturwissenschaften

Motivation

Der Wechsel von präventiver Wartung (en: *Preventive Maintenance*, PM) oder reaktive Wartung (en: *Reactive Maintenance*, RM) zu prädiktive Wartung (en: *Predictive Maintenance*, PdM) bringt viele Vorteile als auch Herausforderungen mit sich. Durch exakt abgestimmte Wartungen kann die Anzahl dieser reduziert werden. Somit sinken Wartungskosten, Austauschkosten als auch Werkspausen und daraus resultierende Pausenkosten durch die geringere Anzahl an Wartungen [1]. Zeitgleich wird proaktiv auf den Verschleiß einzelner Komponenten reagiert, was wiederum Werkspausen durch Maschinenausfälle und somit deren immense Kosten reduzieren kann. Zusätzlich erhöht dies die Werkssicherheit, da sicherheitskritischen Komponenten eine spezielle Aufmerksamkeit gewidmet werden kann. Ein Problem hierbei ist, dass der Verschleiß bei Komponenten sehr unterschiedlich voranschreiten kann: Die Fälle von der Badewannenkurve (hoher Ausfall zu Beginn, sowie Ende der Laufzeit), einer konstanten Ausfallwahrscheinlichkeit oder einer von Betriebsdauer und -intensität abhängigen Ausfallwahrscheinlichkeit sind nur einige mögliche Szenarien [2].

Durch die Einführung von dem Internet der Dinge (en: *Internet of Things*, IoT) und Industrie 4.0 erschließen sich neue Möglichkeiten der PdM. Musste früher ein Wartungsarbeiter über Seh-, Hör- oder Geruchssinn bei einer Inspektion den Zustand einer Maschine ermitteln, kann eine Überwachung wichtiger Maschinenparameter, wie zum Beispiel Vibration, Temperatur oder Schmiermittelkonsistenz, Rückschluss auf den Zustand und Wartungsbedarf einer Komponente geben [3; 4]. Herausforderungen hierbei können das Ermitteln und Generieren benötigter Größen, Anbindung an Cloudinfrastrukturen oder die Unterscheidung von zufälligen Parameteränderungen und korrelierenden Änderungen sein.

Ziel und Vorgehen

Im Rahmen dieser Arbeit soll ein Konzept für Predictive Maintenance ausgearbeitet und für eine wasserbetriebene Lös- bzw. Brandschutzanlage umgesetzt werden. Hierbei wird ein besonderer Fokus auf die Erkennung von Defekten gelegt, da die Erkennung von diesen kritisch für die Sicherheit der Anlage ist. Um die Modelle vor allem für nichterkannte Fehler zu bestrafen wurde mit einer Gewichtsmatrix gearbeitet, welche falsch klassifizierte Defekte doppelt so stark bestraft wie Fehlalarme. Es existieren zwei diverse Ausführungen der Daten: Alte Maschinen nehmen nur einen Wert für Öffnungs- und Schließzeiten sowie Metadaten auf, neue nehmen zudem noch Zeitreihen von Temperatur, Druck und Strom auf.

Die Umsetzung der Lösung erfolgte innerhalb der Microsoft Cloud Plattform Azure mit Hilfe der DataBricks Lösung für die Datenanalyse, -bereinigung sowie Modelltraining und -evaluation. Hierzu wurden diverse Modelle beginnend von statischen Modellen, wie der Regression, über Neuronale Netze und *Automated Machine Learning (AutoML)* entworfen. Diese wurden anschließend mit Rücksicht auf eine solide Fehlererkennung und Gesamtgenauigkeit evaluiert und die besten Modelle im Rahmen eines PoC-Dashboards umgesetzt.

Ergebnisse

Die entworfenen Modelle erreichen, je nach Datengrundlage, eine Genauigkeit von 96-99% bei 97-100% erkannten Fehlern. Werden die Zeitreihen verwendet, wird eine deutlich bessere Fehlererkennung erreicht, was für den Mehraufwand der Erfassung von den Zeitreihen spricht. Aber auch bei Altanlagen, ohne Retrofitting, kann durch die PdM eine gute Klassifizierung der Komponentengesundheit erzielt werden. Auch die Modelle durch AutoML erzielen eine gute Genauigkeit, teilweise müssen jedoch für das beste Ergebnis vorher notwendige Preprocessing Schritte durchgeführt werden.

Als am besten klassifizierendes Netzwerk für diese Problemstellung hat sich das faltende Neuronale Netz (CNN) durchgesetzt, für die Altanlagen schneidet der Random Forest (RF) Algorithmus am besten ab. Alternativ kann der K-nächste Nachbar (KNN) Algorithmus auch auf die Mittelwerte der Zeitreihe angewandt werden, wenn auf Edge-Geräten die Vorhersage geschieht.

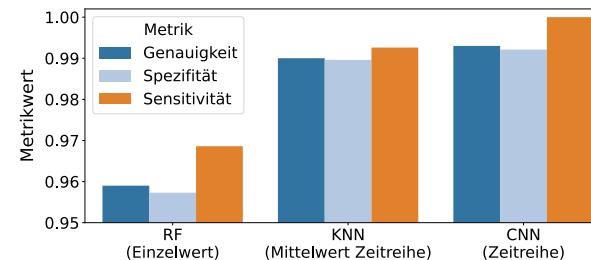


Abb. 1: Metriken der besten Modelle diverser Datengrundlagen

	Nachrichten	ML	Speicher
Anzahl	1.500.000	720 h	30 GB
Kosten	2,08 \$/1M	0,3 \$/h	0,0196 \$/GB
\$/Monat	3,12	216	7,06
Gesamt			226 \$/Monat

Tab. 1: Monatliche Kosten der Cloudlösung bei 10.000 Maschinen

Werden exemplarisch 10.000 Maschinen nach der vorgeschlagenen Architektur in die Cloud implementiert, sind jährliche Kosten von ca. 30 \$ct pro Maschine zu erwarten. Ein Großteil der Kosten wird hierbei von der DataBricks Instanz verursacht, da diese mit dem Preprocessing, als auch den Vorhersagen eine kontinuierlich laufende virtuelle Maschine moderater Größe benötigt. Über das PoC-Dashboard kann der Nutzer die Vorhersagen der Modelle, sowie den Maschinenzustand und die Werte der Zeitreihen über eine Web-App einsehen.

Fazit

Für Alt- als auch Neuanlagen ist auf Basis der Datengrundlage eine gute bis sehr gute Klassifizierung in die Maschinenzustände „Intakt“ und „Defekt“ möglich. Mit Hilfe der Cloudlösung existiert eine solide als auch kostengünstige Plattform für die Implementierung von PdM. Die gestiegenen Fehlererkennungsrate rechtfertigt den Mehraufwand für die neuen, komplexeren Messinstrumente, sowie Datenmenge.

Die Implementierung sollte hybrid mit den alten Wartungsmaßnahmen geschehen und nötige Modellanpassungen auf Basis neuer Datengrundlage durchgeführt werden, bis das Konzept der PdM sicher und zuverlässig ohne parallele Prüfungen ausgeübt werden kann.

Referenzen

- [1] Yongyi Ran, Xin Zhou, Pengfeng Lin, YonggangWen und Ruilong Deng. A Survey of Predictive Maintenance: Systems, Purposes and Approaches. 12. Dez. 2019
- [2] H. M. Hashemian. "State-of-the-Art Predictive Maintenance Techniques". In: IEEE Transactions on Instrumentation and Measurement 60.1 (2011), S. 226–236. issn: 0018-9456.
- [3] Weiting Zhang, Dong Yang und Hongchao Wang. "Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey". In: IEEE Systems Journal 13.3 (2019), S. 2213–2227. issn: 1932-8184.
- [4] Sule Selcuk. "Predictive maintenance, its implementation and latest trends". In: Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture 231.9 (2017), S. 1670–1679. issn: 0954-4054.