

Handlungsempfehlungen für Anlagenbetreiber zur erfolgreichen Einführung von Predictive Maintenance (PdM)

Prof. Dr.-Ing. Karl-Albrecht Klinge, Hochschule Mainz, Mainz

Dr. Waldemar Kisser, infraView GmbH, Mainz

Arno Heidelberg, M.Sc., infraView GmbH, Mainz

Das Thema Predictive Maintenance (PdM) hat in den letzten Jahren für viele Anlagenbetreiber an Bedeutung gewonnen. Unter den Schlagworten Internet of Things (IoT) und Industrie 4.0 werden viele Produkte und Projekte durchgeführt. Verschiedene Firmen konfrontieren die Betreiber mit oft schwer einlösbaren Versprechen („Gib mir deine Daten und ich löse die Verfügbarkeitsprobleme“). Diese Firmen kommen aus unterschiedlichen Bereichen in dieses Thema als Hersteller/ Anbieter von:

- Analysesoftware
- Messeinrichtungen inkl. Edge devices
- Anlagen oder Bauteilen
- Plattformen

Aus Sicht der Autoren können zwar Werkzeuge zur Anwendung am Markt erworben werden. Um die Daten der Anlagen aber wirtschaftlich erfolgreich nutzen zu können muss ein Betreiber gleichzeitig viele interne Strukturen und Prozesse anpassen. Der Artikel verschafft einen Überblick zu diesen Anpassungen.

Dabei sind die besten Vorgehensweisen zwar oft sehr spezifisch – es gibt dennoch einige Gemeinsamkeiten und entsprechende Lösungsansätze, die hier dargestellt werden sollen. Dieser Artikel beschreibt Aspekte, die ein Betreiber bei der geplanten PdM-Einführung beachten sollte, um deren Vorteile optimal auszuschöpfen und die damit verbundenen Risiken erfolgreich zu meistern.

Wichtig dabei ist ein Kompass zur Vorgehensweise:

1. Was sind meine Anforderungen und welchen Nutzen erwarte ich daraus? Zusammengefasst in sogenannten „Nutzergeschichten“ (engl. User Stories) als Rolle, Funktion sowie erwarteter Nutzen.
2. Wo können Hersteller einen wertvollen Beitrag leisten? An welcher Stelle können in diesem Zusammenhang Interessenkonflikte entstehen und wie löse ich diese als Betreiber auf?

Es folgen einige exemplarische User Stories

1 Als Betreiber möchte ich ... die Bedeutung meiner Daten in expliziter Form selbst verstehen, um das Wissen meiner Organisation zu nutzen und weiterentwickeln zu können.

Zur erfolgreichen Anwendung der PdM trägt das Wissen eines Betreibers bei. Dies beinhaltet insbesondere Informationen über das Verhalten der Anlagen unter realen Betriebsbedingungen:

- Die Erfahrungen der Mitarbeiter im Feld und in den technischen Abteilungen.
- Die gesammelten Kontextdaten zu den Anlagen aus den IT-Systemen, wie z.B. Enterprise-Resource-Planning (ERP) oder Geo-Informationen-Systemen (GIS).

Die Hersteller verfügen zwar über das konstruktive Wissen der Anlagen und Bauteile, haben aber selten genügend Informationen zum Anlagenverhalten im Betrieb. Insofern ist es oftmals für die Hersteller schwierig, zum Konstruktionszeitpunkt einer Anlage bereits die für Fehlerfälle relevanten Betriebszustände zu antizipieren und entsprechende Modelle zur Ermittlung der Indikatoren zu erstellen.

Demgegenüber haben Anlagenbetreiber mit zunehmender Betriebszeit genügend Rohdaten zum Anlagenverhalten, können diese aber oftmals nicht verwerten, da die Hersteller alle zur Ermittlung oder Interpretation der Rohdatenpunkte erforderlichen Informationen nicht an die Betreiber herausgeben. Diese Informationen beinhalten z.B.:

- Welche Bedeutung hat der Diagnosecode XY? Wie wird diese Diagnose ermittelt?
- Welche Bedeutung hat die Information X an welcher Busadresse Y? Wie wird diese umgerechnet?
- Was verbirgt sich hinter den „Magischen Nummern“ (engl. Magic Numbers) in der Logdatei?

Oft gibt es schon zur fundamentalen Frage nach den Eigentumsrechten an den Anlagedaten unterschiedliche Auffassungen. Die rechtlichen Aspekte dieser Fragestellung werden in diesem Artikel nicht behandelt. Die Autoren dieses Artikels vertreten die Meinung, dass unabhängig von dieser Entscheidung, beide Parteien nur mit kooperativen Modellen vorankommen, die die Interessen beider Parteien abbilden.

Kann der Betreiber die Anlagendaten in einer verständlichen Form nutzen, so kann er in Kombination mit dem betrieblichen Wissen seiner Mitarbeiter Modelle für wertvolle Indikatoren erstellen.

Dies können zunächst simple Regeln sein („Wenn die [Temperatur X] den [Wert] übersteigt, wird die [Diagnose Y] gestellt, da daraus wahrscheinlich die betriebliche Einschränkung Z folgt.“). Das notwendige Expertenwissen kommen zumeist aus der Betreiberorganisation von den sogenannten „Domänenexperten“, die am besten im Team mit Datenanalysten ihr meist über Jahre der Anwendungserfahrung erworbenes Wissen in die Erstellung von Regeln oder relevanter Eingangsparameter für die Modelle (Feature Engineering) einbringen können. Je weniger Daten über historische Ausfälle vorhanden sind, umso wichtiger ist deren Erfahrung. Bei vielen Ausfällen müssen zudem noch verschiedene Ursachen unterschieden werden, so dass zumeist wenige „ursachenreine“ Datensätze mit Fehlerszenarien zur Modellbildung bereitstehen. Letztes führt dazu, dass stochastische Modelle nicht mit zufriedenstellender Genauigkeit berechnet werden können.

Für die Anwendung von stochastischen „Machine Learning“-Modellen sind eine Vielzahl „ursachenreiner“ Fehlerszenarien aus historischen Daten erforderlich. Diese sind zumeist erst nach längerer Anlagenbetriebszeit vorhanden.

Zudem ist der Aufwand zur Strukturierung der Ursachenkataloge nicht zu unterschätzen. Insbesondere beim überwachten Lernen (engl. Supervised Learning) spielen die Ursachenkataloge eine wichtige Rolle als Ergebnisspalte („Label“). Sie sollten so strukturiert sein, dass:

- Die Mitarbeiter sich im Rahmen der Befundung nicht durch zu viele Ebenen mit zu vielen Begriffen arbeiten müssen. Die Erfahrung in diesem Punkt zeigt, dass ein zunehmender Rückmeldungsanforderung negative mit der Rückmeldungsqualität korreliert. An dieser Stelle ist auch zu beachten, dass Fehler in der Befundung dazu führen, dass die „Maschine“ etwas Falsches lernt (vgl. [1]).
- Die durch die Befundung zugewiesenen Ausfallursachen müssen überschneidungsfrei in Bezug auf „vorhersagbar“ versus „nicht vorhersagbar“ sein. Ein Beispiel: Eine Anlage „Weiche“ kann z.B. aufgrund eines zufällig hineingefallenen „Fremdkörpers“ oder durch einen „Fehler im Klinkenverschluss“ ausfallen. Sollte fälschlicherweise in der Befundung durch den Mitarbeiter „Fehler im Klinkenverschluss“ statt richtigerweise „Fremdkörper“ (oder auch umgekehrt) als Ursache zurückgemeldet werden, so führt dieser Fehler dazu, dass in einem Modell möglicherweise eine nicht vorhandene Vorgeschichte trainiert wird.

Bei Anlagen des gleichen Anlagentyps aber unterschiedlichen Herstellers sollten die Modelle ebenfalls nutzbar sein – dies liefert ein weiteres starkes Argument für eine Standardisierung der Datenpunkte in Kooperation mit den Anlagenbetreibern.

Daraus ergeben sich folgende Handlungsempfehlungen für Betreiber:

1. Bei Bestandsanlagen sollten kooperative Wege mit den Herstellern gefunden werden, um die Anlagendaten zu beiderseitigem Nutzen in verständlicher Form bereitzustellen. Wenn die Betreiber ihre Betriebserfahrung und der Hersteller seine Konstruktionserfahrung einbringen, können bessere Produkte und gesteigerte Betriebsqualität erreicht werden.
2. Für die Datenmodelle der genutzten Anlagen sollen ebenfalls Standards verwendet werden. Fehlen diese Standards für einige Anlagentypen, dann sollten diese ggf. in Kooperation mit anderen Betreibern standardisiert werden. Diese Standards sollten für Neuanlagen verpflichtend von Herstellern bedient werden.
3. Je weniger Daten zu Verfügung stehen, umso wichtiger sind Domänenexperten für den Anlagentyp, um nicht erst nach Jahren positiv verwertbare Ergebnisse zu erzielen.
4. Die Fehlerursache muss möglichst richtig befundet werden.

2 Als Betreiber möchte ich ... Kontextinformation nutzen (z.B. Stammdaten, GIS, Checkpoints, Instandsetzungsdaten, Continuous Track Monitoring (CTM)), um die Richtigkeit meiner Diagnosen und Prognosen zu verbessern.

Je mehr Information über einen Ausfall zur Verfügung steht, umso eher kann die Richtigkeit einer Diagnose verbessert werden. Es ist sinnvoll die Daten zu einem Ausfall in einem Fehlerszenario zu bündeln. Ein Fehlerszenario ist damit die Summe an Daten, die vor einem Ausfall, während und nach der Instandhaltung sowie die Zeit kurz nach der Wiederaufnahme des Regelbetriebs gesammelt werden können.

Das sind die Zustandsdaten, die je nach messbarem Abnutzungsvorrat und Degradationsgeschwindigkeit von Tagen, Wochen bis zu Monaten reichen müssen. Dabei sind in vielen Fällen nicht nur die Zustandsdaten der überwachten Anlage selbst relevant, sondern auch Daten von Anlagen, die eine funktionale Abhängigkeit zur betrachteten Anlage oder speziell eines ihrer Bauteile haben.

Zusätzlich sind noch Kontextdaten der Anlage für das Fehlerszenario wichtig. Diese Kontextdaten werden i.d.R. aus umliegenden Systemen bezogen, insbesondere aus Enterprise Resource Planning Systemen (ERP, z.B. SAP oder Maximo), GIS-Systemen, Instandhaltungssystemen und z.B. Wetterdiensten.

Dazu kommt die Befundung mit Angabe einer Fehlerursache sowie weitere Daten zur Reparatur der Anlage (z.B. welche Ersatzteile wurden im Rahmen der Instandhaltung abgerufen, wie lange hat die Reparatur gedauert).

Auch die Anlagendaten unmittelbar nach der Instandhaltung und Wiederaufnahme in den Regelbetrieb können dazu beitragen, stochastische Modelle zu verbessern. Diese Informationen sind in Mehrklassenalgorithmien als Abgrenzung zu den „Fehlerklassen“ als Klasse „Optimalzustand“ verwertbar. Auch lässt sich mit diesen Daten überprüfen ob eine (erneut) in Betrieb gestellte Anlage wieder optimal funktioniert und die nun gesendeten Daten stochastisch zu den historischen Optimaldaten passen.

Aus Sicht der „Machine Learning“ (ML)-Begriffswelt stellt ein Fehlerszenario damit eine „Zeile“ in der Trainingsdatenbank dar. Die oben genannten Zustands- und Kontextdaten stellen die Input-Daten dar, die Befundung mit Ursache („Root Cause“) den Output (meist als „Label“ bezeichnet).

Mit Hilfe einer solchen Trainingsdatenbank können ML-Modelle gelernt und – sehr wichtig – vor Produktiveren eines Modells validiert werden.

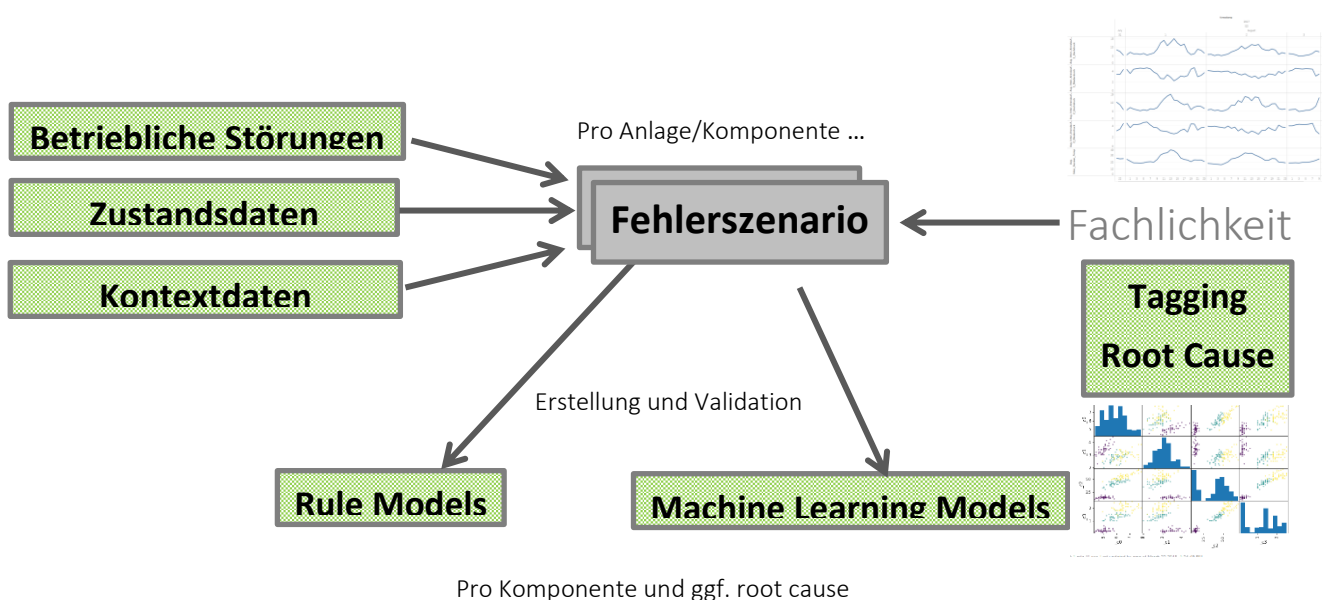


Abb. 1: Fehlerszenario (eigene Abbildung)

3 Zusammenfassung

Der vorliegende Artikel möchte den geeigneten Leser sensibilisieren, dass die Predictive-Maintenance-Einführung nicht nur als technisches Thema gesehen wird. Es genügt nicht, Sensoren und ein Softwaresystem zu beschaffen. Vielmehr erfordert Predictive-Maintenance ein umfangreiches Change-Management in der Organisation. Hierzu zählt auch die Fokussierung der Organisation auf Datenqualität. Nach außen muss der Umgang mit Herstellern neu ausgerichtet werden, damit die Daten friktionsfrei für das gemeinsame Ziel von Produkten mit besseren betrieblichen Eigenschaften genutzt werden können.

4 Literatur

- [1] https://www.bigdata.fraunhofer.de/content/dam/bigdata/de/documents/Publikationen/BMBF_Fraunhofer_ML-Ergebnisbericht_Gesamt.pdf Seite 26, Online-Ressource abgerufen am: 2019-08-20