

Datengetriebene Module für Predictive Maintenance

Betrachtung verschiedener Module für eine datengetriebene, vorausschauende Wartung

Burkhard Hoppenstedt, Rüdiger Pryss, Alexander Treß, Bernd Biechele und Manfred Reichert

Der Wunsch aus Produktionsdaten einen vorausschauenden Wartungszyklus abzuleiten, definiert das Umfeld des Themengebiets Predictive Maintenance. Hierbei unterscheiden sich die jeweiligen Anforderungen an eine Anwendung sehr stark, u. a. aufgrund der zugrunde liegenden Datenbasis, bestehenden Echtzeitanforderungen und vorhandenem Expertenwissen. Im Folgenden wird erörtert, welche Module in den Kreislauf eines Predictive Maintenance Systems einfließen können. Ein Schwerpunkt liegt auf der Datenreduktion mittels der Principal Component Analysis.

Das Themengebiet Predictive Maintenance ist kein neues Thema. Inhaltlich bewegt es sich im Themenumfeld der Automatisierung und kann softwareseitig in ein Manufacturing Execution System integriert werden (vgl. Bild 1). Die Integration ermöglicht es wiederum, dass Ergebnisse aus der Auswertung von Maschinendaten in die Produktionskontrolle miteinbezogen werden können. Im ersten Teil dieses Beitrags stellen wir ein Predictive Maintenance System anhand einer grundlegenden Modulstruktur vor (vgl. Bild 2) und diskutieren ausgewählte Module (vgl. die fettgedruckten Module im Folgenden mit Bild 2). Anschließend stellen wir entlang eines realen Industriedatensatzes eine Methode zur Datenreduktion vor, die einen wichtigen Bestandteil im Kontext von Predictive Maintenance darstellen kann.

Teil 1: Modulstruktur für Predictive Maintenance Systeme

Aufgrund der umfangreichen Funktionalitäten eines Predictive Maintenance Systems, wurde ein Übersichtsschaubild der Komponenten entwickelt (vgl. Bild 2). Dieses wird im Folgenden erläutert. Zur Einführung eines Predictive Maintenance Systems [1] muss eine Datenbasis des gesamten Maschinenzustandes extrahiert werden. Um dies zu ermöglichen, ist folgende Frage von zentraler Bedeutung: Welche Genauigkeit wird für die Messdaten benötigt? Die Aufgabe des verantwortlichen Sensormoduls liegt darin, (a) einen kontinuierlichen Verlauf der Maschinensignale durch Abtastung zu diskretisieren, (b) die gewünschte Signalaufösung durch Quantisierung festzulegen sowie ggf. (c) eine Metastruktur zur Organisation der Daten zu

identifizieren. Eine Metastruktur könnte entstehen, indem die Maschinensignale mit der Protokollsprache Open Platform Communication Unified Architecture (OPC-UA) softwareseitig wiederum als Maschine abgebildet werden. Um Fehler bei der Übertragung von kontinuierlichen zu diskreten Werten während der Abtastung zu vermeiden, sollte das Nyquist-Shannon-Abtasttheorem [2] beachtet werden, welches eine vollständige Rekonstruktion des Ursprungssignals ermöglicht, indem die Abtastrate größer als die doppelte Ursprungsfrequenz des Datensatzes gewählt wird (d. h. $f_{\text{abtast}} > 2 \cdot f_{\text{max}(\text{signal})}$). Im Bereich von Maschinen mit hochfrequenten Signalen führt dies zu sehr hohen Anforderungen an die Sensorik. Mittels der Quantisierung kann eine verlustbehaftete Kompression durchgeführt werden. Durch das Auf- oder Abrunden des Signalwertes auf die nächste Quantisierungsstufe, welche durch die Schrittweite Δ ermittelt wird, ergibt sich der verwendete diskrete Wert. Der Quantisierungsfehler wird durch die mittlere quadratische Abweichung (engl. MSE – Mean Square Error) angegeben. Nach diesen zwei Schritten liegt der gemessene Wert digital im System vor und kann durch Meta-Informationen wie Maschineninformationen (z. B. Laufzeit) ergänzt werden. Um die Sinnhaftigkeit der erhaltenen Werte zu überprüfen, wird optional das Modul Data Quality ausgeführt. Folgende Fragestellungen sind in diesem Kontext relevant:

- **Consistency:** Sind die Daten konsistent?
- **Validity:** Passt die Intervallzuordnung und der Datentyp?
- **Completeness:** Sind alle Sensorwerte gesetzt oder gab es NULL-Einträge?

In diesem Beitrag lesen Sie:

- ✓ aus welchen Modulen ein Predictive Maintenance System aufgebaut sein kann,
- ✓ wie sich diese Module miteinander kombinieren lassen und
- ✓ wie eine Datenreduktion mit der Principal Component Analysis auf Maschinendaten aussehen kann.

M. Sc. Burkhard Hoppenstedt ist externer wissenschaftlicher Mitarbeiter am Institut für Datenbanken und Informationssysteme (DBIS) der Universität Ulm. Seine Promotion befasst sich mit Predictive Methoden im Umfeld von Manufacturing Execution Systems.

Dr. Rüdiger Pryss ist Habilitand am Institut für Datenbanken und Informationssysteme und beschäftigt sich in seiner Forschung mit der innovativen Datensammlung durch den Einsatz mobiler Technologien und ihrer Verknüpfung mit prozessorientierten Informationssystemen.

Dipl.-Inf. Alexander Treß ist Geschäftsführer der atr Software GmbH, deren Spezialgebiete die Automatisierungstechnik und Produktionsplanungssysteme sind.

Prof. Dr. Manfred Reichert ist Direktor des Instituts für Datenbanken und Informationssysteme an der Universität Ulm. In seiner Forschung entwickelt er adaptive Prozess Management Technologien der nächsten Generation.

Dipl.-Inf. Bernd Biechele leitet die Softwareentwicklung der EOS GmbH, die industrielle 3D-Drucker herstellt.

www.uni-ulm.de/dbis
www.atr-software.de

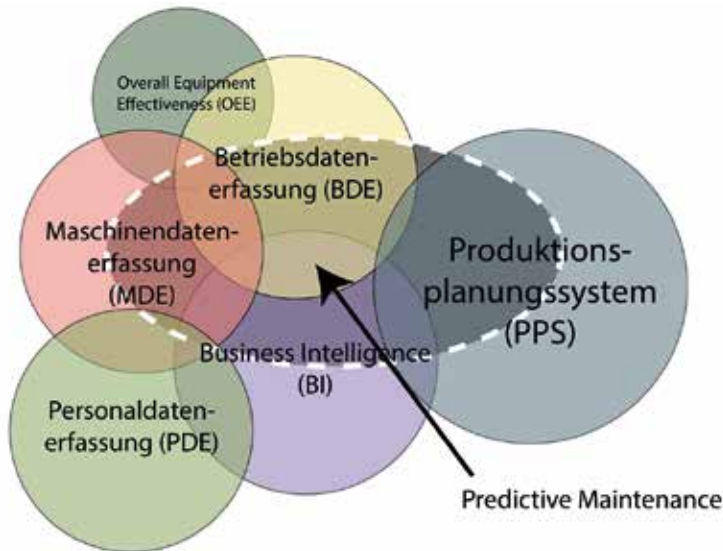


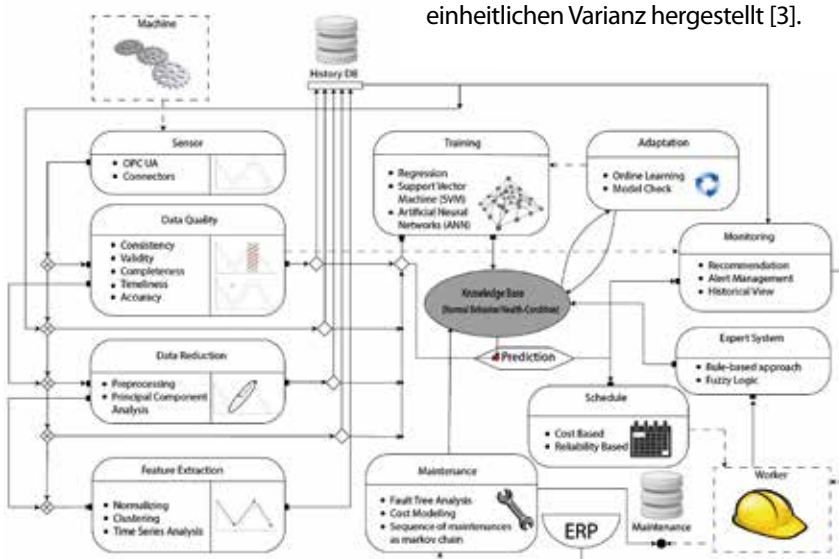
Bild 1: Predictive Maintenance kann Teil eines MES sein. Jedoch ist es kein isoliertes Modul, sondern es nutzt, erweitert und steuert vorhandene Module.

- *Timeliness:* Lassen die Zeitstempel Rückschlüsse auf Verzögerungen zu?
- *Accuracy:* Ist die Auflösung gut genug gewählt worden (vgl. MSE)?

Sollte eine dieser Bedingungen verletzt sein, kann ein Datensatz in der Datenbank als korrupt markiert werden und ein Hinweis an das Monitoringmodul gesendet werden. In einem Dashboard werden Verlaufsinformationen, Hinweise und Empfehlungen visualisiert. Eine Verletzung der Completeness-Bedingung könnte beispielsweise durch den Hinweis aufbereitet werden, dass nicht alle benötigten Sensoren angeschlossen sind.

Um Zusammenhänge innerhalb der Signale zu erkennen, muss eine Feature Extraction angewandt werden. Eine Datenkurve wird zuerst in Teilkurven unterteilt und anschließend mit verschiedenen Methoden des Data-Minings oder der Zeitreihenanalyse analysiert. Eine Vergleichbarkeit der Daten wird durch die Normalisierung zu zero mean in Kombination mit einer einheitlichen Varianz hergestellt [3].

Bild 2: Module eines leistungsfähigen Predictive Maintenance Systems.



Um ein System „predictive“ zu machen, muss zunächst eine Wissensbasis anhand der vergangenen Daten angelernt werden, um darauf basierend Prognosen für die weitere Entwicklung aufzustellen. Ein üblicher Ansatz für das Anlernen bzw. Training stellen Neuronale Netze [4] dar, welche eine Inputmenge mittels einer variablen Anzahl von Verbindungsknoten auf eine Ausgabe verrechnen. Die Gewichtung der Zwischenknoten kann über eine Rückwärtsberechnung antrainiert werden. Mittels einer Brute Force-Testmethode kann zudem die Anzahl der Verbindungsknoten ermittelt werden, indem das beste Resultat aus einem getesteten Intervall (vgl. [3]) verwendet wird. An dieser Stelle ist jedoch Vorsicht angebracht, da ein intensiviertes Lernen nicht immer besser ist. So kann es passieren, dass bei verstärktem Lernen viele, auch nebensächliche, Aspekte antrainiert werden. Bei iterativen Lernalgorithmen kann hier die sogenannte Early Stopping Regularization eingesetzt werden, um diesen Effekt zu verhindern. Sequentielles Anlernen ist wesentlich komplexer als Lernen auf einem ganzen Datensatz, weil das Entfernen des Rauschens (Noise) und das nachträgliche Zuordnen zu einem Cluster erschwert werden [5].

Alle nun berechneten Informationen werden in einer Wissensbasis (Knowledge Base) verwaltet. Der ermittelte Zustand der Maschine und der Abgleich der aktuellen Daten mit einem antrainierten Normalzustand ermöglichen wiederum eine Vorhersage. Es ist an dieser Stelle ratsam, menschliches Expertenwissen mit in die Wissensbasis aufzunehmen. Für die Modellierung von Expertenwissen ist die sogenannte Fuzzy Logic [6] ein sinnvolles Instrument, weil viele Regeln ineinandergreifen und nicht klar gegeneinander abgegrenzt werden können.

Mithilfe der entstandenen Wissensbasis, die sich aus dem Dateninput und dem Expertenwissen speist, wird ein Wartungszyklus aufgebaut. Die Produktionsoptimierung kann entweder eine quantifizierte oder eine qualitative Zielsetzung haben. Während im quantifizierten Ansatz die Maximierung der Verfügbarkeit bei gegebenen Instandhaltungskosten das Ziel ist, wird im qualitativen Ansatz die Reduktion der Instandhaltungskosten bei Erhalt der Verfügbarkeit in den Vordergrund gestellt.

Teil 2: Datenreduktion im konkreten Anwendungsszenario

Die auszuwertenden Daten liefert eine industrielle 3D-Druckmaschine, von welcher zehn messende Sensoren untersucht wurden. Die Sensoren liefern Positions-, Geschwindigkeits-, Temperatur-, Druck- und Gaskonzentrations-