

Ein Plattform-Ökosystem für Predictive Maintenance zur Erhöhung der Effizienz und Effektivität der Instandhaltung in kleinen und mittleren Unternehmen (KMU)

Matthias Nagel – Simba n³

Natanael Arndt – InfAI Management GmbH

Fabian Förster – Fraunhofer IML

Matthes Nagel – Simba n³

Ralph Riedel – Technische Universität Chemnitz

Abstract

Daten spielen im modernen wirtschaftlichen Handeln eine immer größere Rolle. Jedoch bleibt der Wert der Daten durch den Verbleib beim Eigentümer oft ungenutzt. IIoT und Industrie 4.0 Angebote von großen Technologiekonzernen werden jedoch nicht den Anforderungen und Bedenken von KMU in Hinblick auf die Datensicherheit und die damit verbundene Wahrung von Geschäftsgeheimnissen gerecht. Im vorliegenden Artikel wird der Mehrwert der vernetzten Nutzung von Maschinendaten zur Ermöglichung von vorausschauender Instandhaltung auf einer Plattform gezeigt. Die Gewährleistung der Datensicherheit spielt beim Entwurf der Plattform bereits eine konzeptionelle Rolle. Es werden verschiedene Arten der Analyse der Daten zur Vorhersage von Ausfällen vorgestellt. Der Artikel wird durch eine Betrachtung zur wirtschaftlichen Nutzung der Analyseergebnisse abgeschlossen.

1 Predictive Maintenance als digitales Geschäftsmodell

Predictive Maintenance – die vorausschauende Instandhaltung – ermöglicht neue digitale Geschäftsmodelle und ist als Grundbaustein für Industrie 4.0 in der industriellen Praxis angekommen. Durch eine gezielte Datenanalyse können mögliche Ausfälle von Komponenten frühzeitig erkannt werden, sodass präventive Maßnahmen eingeleitet und Schäden durch vorbeugendes Warten bereits im Vorfeld vermieden werden. Der Vorteil liegt in der Wirtschaftlichkeit, da sich enorme Kosten sparen lassen, zumal sich ungeplante Ausfälle direkt auf den Unternehmensgewinn auswirken (Coleman, C., Damodaran, S., Chandramouli, M. & Deuel, E., 2017). Durch die gewonnene Planbarkeit können bisher reaktiv gehandhabte Störfälle in präventive Wartungen überführt und Ausfallfolgekosten somit unmittelbar vermieden werden. Neben der Vermeidung ungeplanter Maßnahmen besteht ein wirtschaftliches Potenzial darin, Wartungszyklen an die gegenwärtigen Gegebenheiten anzupassen. Hier kann vor dem Hintergrund einer zu bewahrenden Auslastung eine bedarfsgerechte sowie zustandsorientierte Priorisierung von Wartungen erfolgen. Obwohl gerade industrielle KMUs über das Thema Predictive Maintenance schlank und frühzeitig in ihre digitale Transformation einsteigen könnten, sind u.a. der (IT)-Fachkräftemangel und hohe Investitionskosten Hürden für den industriellen Mittelstand für den Einsatz von Predictive Maintenance.

2 Voraussetzungen für Predictive Maintenance

An einer Umsetzung von Predictive Maintenance sind Maschinenbetreiber, Maschinenhersteller, Servicetechniker und Anbieter von Dienstleistungen zur Datenanalyse (Analyseanbieter) beteiligt. Die für Predictive Maintenance relevanten Daten müssen durch den Maschinenbetreiber erfasst und bereitgestellt werden können. Oftmals reichen aber die im Unternehmen verfügbaren Daten dafür nicht aus, um überhaupt solche Analysen durchführen

zu können. Eine typische Situation dafür ist beispielsweise, dass eine neue digitale Maschine angeschafft wurde, die man proaktiv warten möchte. Man hat dafür zwar granulare Sensor- und Maschinendaten zur Verfügung. Es fehlen dazu noch Ereignisse wie Störungen und Wartung, um diesen Ereignissen die Maschinendaten zuordnen zu können, als Voraussetzung, um daraus zu lernen.

Die gesammelten maschinenbezogenen Daten sind gemeinsam mit Ereignissen zu analysieren, um damit Entscheidungsunterstützung zu bekommen, ob man auf Grundlage der von Predictive Maintenance-Modellen prognostizierten Ausfallrisiken proaktiv wartet oder weiter produziert, bis die Maschine oder Anlage durch eine Störung ausfällt. Eine solche Entscheidung ist nicht trivial und daher nicht ohne weiteres zu treffen, müssen dazu doch ökonomische Risiken abgewogen werden. All das findet im Kontext einer industriellen Datenanalyse (Reinhard, F. 2016) statt, welche diverse Disziplinen umfasst (vgl. Abbildung 1). Als Resultat des Analyseprozesses erwartet der Maschinenbetreiber eine Aufbereitung der Daten zusammen mit möglichen Handlungsempfehlungen oder gar eine Eintaktung der Wartung in den Produktionsprozess zu erhalten (Förster, F., Müller, D., Scholz, D., Michalik, A. & Kiebler, L., 2019).

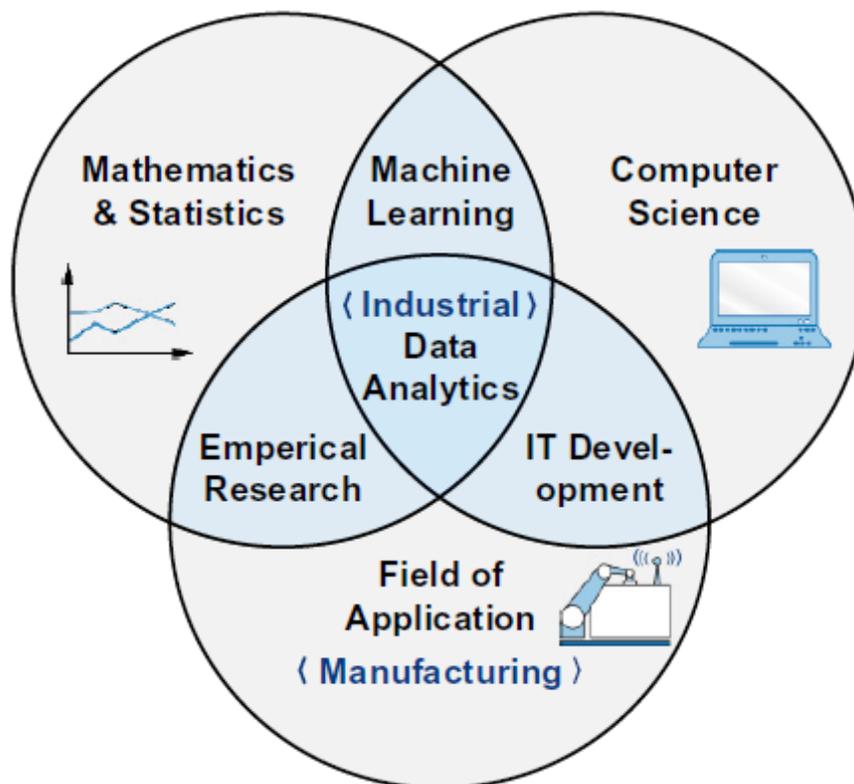


Abbildung 1: Charakterisierung von industriellen Datenanalysen durch die daran beteiligte Disziplinen

Dabei spielen alle möglichen Daten und Parameter eine Rolle, welche im Kontext zu einer Maschine stehen, also neben Mess- und Sensordaten zur Maschine auch die Stammdaten, Wartungs-, Reparaturberichte und Störungsprotokolle, Fehlermeldungen und Verbrauchsdaten („Wie intensiv wurde die Maschine in einem Zeitintervall genutzt?“). Aus dem zeitlichen Verlauf der Maschinenprozesse, die lediglich durch Ereignisse unterbrochen werden, erkennt man auch den Verbrauch, den eine Maschine seit dem letzten Ereignis (z.B. letzter Instandsetzung) bis zur nächsten Störung erlebt hat. Damit werden Störungen als Ereignisse definiert, die einen Prozess unterbrechen und für die vollständigen Informationen zu den Ursachen und daraus resultierenden Maßnahmen zur Verfügung stehen. Aus solchen Ereignisdaten lassen sich die Risiken für das Auftreten von Störungen über Wahrscheinlichkeitsmodelle berechnen.

Liegen darüber hinaus Maschinen- oder Sensordaten vor, können diese, wie in Abb. 2 veranschaulicht, mittels der Ereignisse in „Daten vor einem Störeignis“ (roter Bereich) und „Daten nach erfolgter Instandsetzung“ (grüner Bereich) klassifiziert werden. Ereignisse sind eine Grundvoraussetzung dafür, um mittels Machine Learning nach Korrelationen zwischen Maschinendaten und Ereignissen und weiteren Informationen zu Maschinen suchen zu können (Nagel, M., Riedel, R. 2018). Die Kombination von Ereignissen, deren Ursachen und den Maschinendaten sind damit die Basis für weitere Modelle zum Predictive Maintenance. In Abb. 2 wird dieser Zusammenhang verdeutlicht.

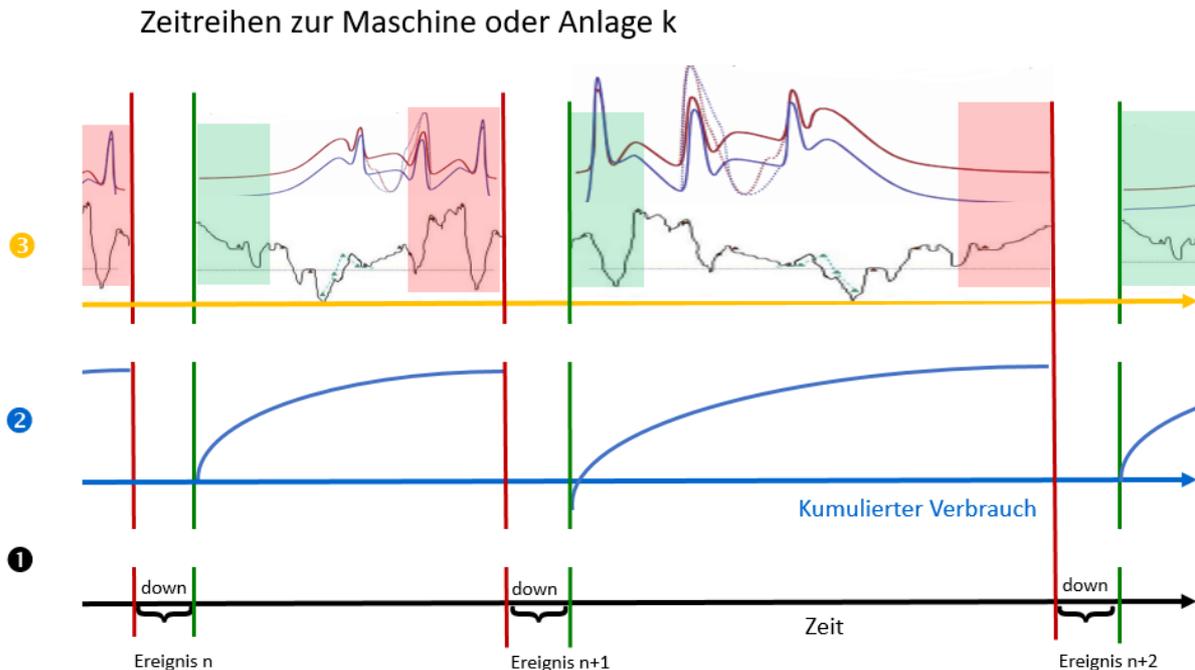


Abbildung 2: Zeitreihen zu Maschinendaten und Ereignisse

In Abbildung 3 ist in Zeile (1) unten für eine Maschine oder Anlage der Prozessverlauf als Zeitreihe und Abfolge von Funktion bis zu einem Ereignis (rote vertikale Linie) dargestellt, durch das die Funktion unterbrochen wird (down). Nach z.B. einer Reparatur wird die Maschine wieder in Betrieb genommen (grüne vertikale Linie), usw. Zu diesem Zeitpunkt kennt man die Ursachen für das Ereignis und die erforderlichen Maßnahmen, um die Funktionsfähigkeit wiederherzustellen. Die Zeile (2) enthält den kumulierten Verbrauch zwischen Herstellung der Funktionsfähigkeit und dem nächsten Ereignis. Im einfachsten Fall kann das der kumulierte Stromverbrauch als Indikator für den Verbrauch sei. Besser wären allerdings spezifische Parameter wie z.B. der kumulierte Spindelvorschub bei einer Bohrmaschine. In Zeile (3) sind symbolisch Zeitreihen von Sensordaten dargestellt. Um diese mittels Machine Learning für Predictive Maintenance-Modelle zu nutzen, müssen zumindest initial die Sensorwerte mit Ereignissen korreliert werden. Rot hinterlegt sind Zeitbereiche von Sensordaten, die mit Ausfällen in Beziehung stehen sollten. Aus den grün hinterlegten Bereichen sind Korrelationen zum guten Zustand zu ermitteln.

Zur Erschließung von Datenquellen für PlatonaM wird Machine Learning im Prozesskontext eingesetzt. Die Machbarkeit der Anwendung von Symbolic Machine Learning auf maschinellen Event Logs und Sensordaten in der Semantic Web Domäne wurde bereits durch Bin et al. (Bin, Westphal, Lehmann & Ngonga-Ngomo, 2017) gezeigt. Zur Erschließung der heterogenen Datenquellen, die für Predictive Maintenance-Modelle benötigt und im PlatonaM-Ökosystem verwendet werden, sind multimodale Machine-Learning Methoden vorgesehen. Darunter ist u.a. die Verarbeitung von Textberichten zu Ausfall- oder Störungseignissen zu verstehen, aus

denen die Ereignisse extrahiert werden, die zu Ausfällen führen. Ohne Ereignisse, die sich durch diese vorausgehenden Sensordaten abzeichnen, ist kein sinnvolles Machine Learning mit Sensordaten möglich. Die extrahierten Daten z.B. aus den Serviceberichten sind außerdem die Grundlage für Risikomodelle. Darüber hinaus sollen auch semistrukturierte Daten wie Fehlermeldungen zusammen mit Messwerten zu Maschinen wie für Predictive Maintenance genutzt werden, um Zusammenhänge zu ermitteln. Die für Predictive Maintenance relevanten und wichtigsten Daten sind in Tabelle 1 zusammengestellt. Für Reliability Centered Modeling (RCM), oft auch als Risk Based Maintenance bezeichnet, sind neben den Zuständen der Maschine besonders Angaben zum Verbrauch wichtig. In der Tabelle steht bei der Verfügbarkeit der Daten K für Kunde bzw. Betreiber der Maschine, H für Hersteller und S für Service, der wiederum vom Hersteller, teilweise vom Kunden oder externen Dienstleistern erfolgen kann.

Tabelle 1: Zusammenstellung relevanter Daten, die für Predictive Maintenance erforderlich sind.

Nr	Daten zu	Inhalte	hat diese	liegen vor	erfügbar	Typ	werden benötigt für
1	Stammdaten Maschine	Hersteller, Typ, Maschinen-ID	alle: K, H, S	DB	hoch		Klassifikation und Zuordnung
2	Störungen	Ausfalldatum	alle: K, H, S	meist manuell	hoch	Datum, diskretes Ereignis	Klassifikation und Zuordnung
3	Reparaturberichte	Reparaturbeginn, Ursache, Aktion, Baugruppen, Teile, Wiederinbetriebnahme, Kosten	alle: K, H, S	manuell	hoch	Datum, Text	Modellierung & Prädiktion
4	Verbrauch bis letzter Störung	Energieverbrauch	K	digital	teilweise	stetig	Modellierung & Prädiktion
5	Verbrauch bis letzter Störung	div. Leistungsparameter der Maschine	K, H	digital	teilweise	stetig	Modellierung & Prädiktion
6	Verbrauch bis letzter Störung	Produktion (aus ERP)	K	manuell	prinzipiell verfügbar	stetig	Modellierung & Prädiktion
7	Maschinenmeldungen	(Fehler)codes und Beschreibungen	K	digital	hoch	diskretes Ereignis	Modellierung & Prädiktion
8	Maschinenparameter	Sensoren	K, H	digital	teilweise	Zeitreihen	Modellierung & Prädiktion
9	Maschinenparameter	log Files	K, H	digital	teilweise	Zeitreihen	Modellierung & Prädiktion

3 Dateninfrastruktur als Herausforderung

Große Technologiekonzerne stellen IIoT Plattformen für Industrie 4.0 Anwendungen zur Verfügung, wie Siemens MindSphere¹ und BOSCH². Diese Plattformen verfügen unter anderem über Predictive Maintenance Angebote. Mittelständige Unternehmen haben jedoch Bedenken bei dem Einsatz von zur Verfügung stehenden Predictive Maintenance Lösungen. Hürden stellen (1) hohe Investitionskosten für die Einrichtung von Predictive Maintenance, (2) Anforderungen an den Datenschutz und die Datensicherheit und (3) die schwer zu überblickende Komplexität des Themas IIoT und Industrie 4.0 dar. Zudem ist der Fachkräftemangel durch eine schwächere Position auf dem Stellenmarkt bei kleineren Unternehmen real, gute Kräfte gehen oft aufgrund einer besseren Entlohnung zu großen Unternehmen. Die Möglichkeit des Outsourcings und damit der Weitergabe der Daten an proprietäre Lösungen steht allerdings im Kontrast zu unklaren Datenschutz Standards, einem unklaren Rechtsrahmen und mangelndem Vertrauen.

¹ <https://new.siemens.com/global/de/produkte/software/mindsphere.html>

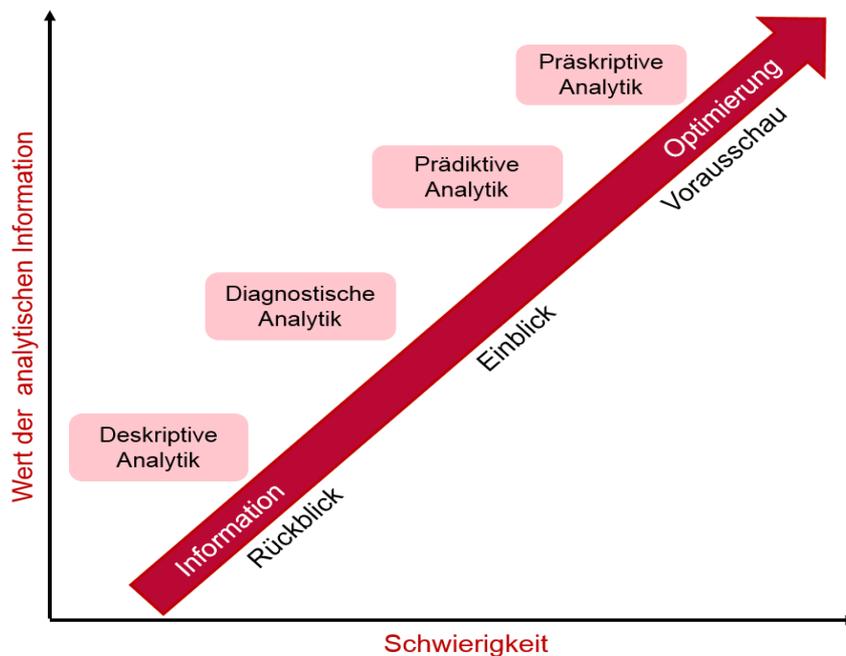
² <https://www.bosch-iiot-suite.com/>

Zur Umsetzung von Predictive Maintenance ist eine umfassende Ausstattung der Maschinen mit Sensorik notwendig. Die ist bei alten Maschinen aber schwieriger als bei digitalen Maschinen umzusetzen. Viele Produktionsbetriebe nutzen Maschinen und Anlagen, die 20 Jahre oder älter sind. Eine Erweiterung des Maschinenparks um digitale Komponenten stellt einen Angriffsvektor für Hackerangriffe dar, welche eigene Lösungen zur Gefahr werden lassen können. Die digitale Kompetenz ist bei KMU ungleich verteilt. Daher stellt der Aufbau einer parallelen Datenwelt, getrennt vom Produktionsnetzwerk welches dadurch nicht von außen angegriffen werden kann, eine sinnvolle Alternative dar.

Die Initiative International Data Space (IDS, Otto, B., Jürjens, J., Schon, J., Auer, S., Menz, N., Wenzel, S. & Cirullies, J., 2016) entwickelt eine Referenzarchitektur (Otto, B., Lohmann, S., Steinbuß, S. & Teuscher, A., 2018) zum Aufbau einer Dateninfrastruktur zur Vernetzung von industriellen Partnern. Insbesondere die Business Privacy spielt im IDS eine wichtige Rolle und wird durch die konsequente Erhaltung der Datenhoheit durch die Dateneigentümer erreicht. Die Vermittlung zwischen den beteiligten Dateneigentümern wird durch Broker durchgeführt und die Durchführung von bilateralen Geschäftsbeziehungen durch ein Clearing House überwacht.

4 Predictive Maintenance aus analytischer Sicht

In der Terminologie ist zwischen Predictive Analytics und Predictive Technologies zu unterscheiden. Predictive Analytics wird für Vorhersagen über unbekannte zukünftige Ereignisse verwendet. Predictive Analytics wird erst durch Predictive Technologies möglich, die Sensorik (z.B. für Schwingungen, Ölstand, Temperatur, Stromverbrauch und Geräusche) und die Informationsverarbeitung umfassen, um z.B. erste Warnsignale für ein mögliches Eintreten eines Ereignisses zu liefern. Für Predictive Analytics - d.h. für die Analysen von Daten mit dem Ziel, Aussagen über die Zukunft treffen zu können, werden Techniken eingesetzt, die zu Data Mining, Statistik, Modellierung, maschinellem Lernen und künstlicher Intelligenz gehören. Eine Übersicht über prädiktive Modelle für Industrieanwendungen gibt O. Merkt (O. Merkt, 2019). Gartner unterscheidet in einem Reifegradmodell zwischen vier analytischen Niveaus (Nagel, M., Riedel, R, 2018), vgl. Abbildung 3:



nach „Analytic Value Escalator“ von Gartner

Abbildung 3: Reifegradmodell für Analytics nach Gartner

- **Descriptive Analytics** beschäftigt sich damit, aus der Vergangenheit zu lernen, um dann in Zukunft besser entscheiden zu können.
- **Diagnostic Analytics** folgt oft der Descriptive Analytic, um Einblicke in Ursachen und Zusammenhänge zu bekommen.
- **Predictive Analytics** beschäftigt sich mit der Zukunft und ermöglicht eine Abschätzung der Wahrscheinlichkeit des Eintretens eines zukünftigen Ereignisses. Um Muster in Daten zu entdecken, werden historische und aktuelle Daten genutzt, um darin mittels statistischer Modelle und Algorithmen Beziehungen in den Daten zu suchen.
- **Prescriptive Analytics** setzt auf Predictive Analytics auf und versucht, Auswirkungen zukünftiger Entscheidungen abzuschätzen und zu bewerten, bevor Entscheidungen getroffen werden.

Zum Erkenntnisgewinn über den Zustand von Maschinen und dessen Entwicklung tragen alle einzelnen analytischen Stufen wesentlich bei. Mit dem Wert an analytischen Informationen aus den Daten und Informationen zu den Maschinen steigen auch die Anforderungen an deren Aufbereitung und an das datenanalytische und algorithmische Verständnis, insbesondere für eine prädiktive und präskriptive Analytik. Oftmals übersteigt das die Möglichkeiten von KMU, sodass eine diesbezügliche analytische Unterstützung wünschenswert und erforderlich ist.

5 Das PlatonaM-Ökosystem

Mit PlatonaM³ wird ein Plattform-Ökosystem entwickelt, welches komplexe Geflechte von Geschäftsbeziehungen und Datenflüssen zwischen Maschinenbetreibern und -herstellern auflöst und in ein organisiertes Netzwerk von effizienten N:1:M Beziehungen für den Anwendungsfall Predictive Maintenance überführt. Dieses Netzwerk bietet allen Beteiligten (Maschinenbetreiber, -hersteller, Datenanalyse- und Instandhaltungsunternehmen) einen gemeinsamen Marktplatz zum Angebot und zum bedarfsgerechten flexiblen („on demand“) Abruf der jeweiligen Dienstleistungen. Dienstleistungen des Plattform-Ökosystems umfassen den Austausch von Daten als Wirtschaftsgut, die Organisation der Dateninfrastruktur für diesen Datenaustausch und Datenanalysen für Predictive Maintenance. Abbildung 4 zeigt das Zusammenspiel der Teilnehmer an der PlatonaM Plattform. Die Maschinendaten werden in einem Repository verzeichnet. Zur Analyse der Daten werden verfügbare Angebote aus dem Verzeichnis der Analysesoftware genutzt. Nach der Ausführung der Analyse werden die resultierenden Ergebnisse dem Plattformnutzer wieder zur Verfügung gestellt. Zur Wahrung der Business Privacy und Datensouveränität werden alle Datenpakete vor der Abspeicherung in der Plattform verschlüsselt oder Anonymisiert. Die Vorteile von PlatonaM liegen in Netzwerkeffekten zwischen Maschinenbetreibern Maschinenherstellern, Anbietern von Analysesoftware und Servicetechnikern. Über die Plattform PlatonaM können eigene Daten zusammen mit dazu passenden Daten anderer Plattformnutzer analysiert werden. Da die dafür notwendigen Daten und Algorithmen zu deren Analyse ein Wirtschaftsgut darstellen, ist bei Nutzung dafür zu bezahlen: Daten von unterschiedlichen Sensoren und aus unterschiedlichen Bereichen eines Betriebs haben einen unterschiedlichen Einfluss für prädiktiven Analyseverfahren. Damit wird ein unterschiedlicher Wert der Daten begründet.

Für einen Erfolg des PlatonaM Ökosystems ist die Bereitstellung von Maschinendaten durch den Maschinenbetreiber entscheidend. Das wiederum erfordert die Wahrung von Geschäftsgeheimnissen, um Marktvorteile aufrecht zu erhalten. Business Privacy in der zwischenbetrieblichen Kommunikation ist daher eine zwingende Notwendigkeit. Im PlatonaM Ökosystem wird daher von vornherein höchstes Augenmerk auf den unternehmerischen Datenschutz gerichtet. Die Sensibilität der Daten muss durch den Maschinenbetreiber vorgegeben werden können. Sie reicht auf einer Skala von hoch sensibel – darf nur in Bezug auf die eigene Maschine genutzt werden – über die Möglichkeiten des Zugriffs durch andere

³ <https://platona-m.technology/>

- Projektpartner sammeln Maschinen- und Sensordaten, um darauf
- Machine Learning-Algorithmen erproben zu können.
- Fehlercodes von Maschinen werden gesammelt. Dazu ist der Situation Rechnung zu tragen, dass Fehlermeldungen von der digitalen Steuerung teilweise ohne Ursachenbezug ausgegeben werden. Werden Fehlercodes zusammen mit Sensordaten analysiert, besteht eine gute Chance, hierfür eine Klassifikation und Ursachenzuordnung vornehmen zu können.
- Ein wichtiger Arbeitsschwerpunkt ist die Definition von Anwendungsszenarien für die PlatonaM Plattform, bestimmen doch diese die dafür erforderlichen Daten, die Methoden und den Grad der erforderlichen Datensicherheit.

Ausgehend von typischen Situationen resultieren konkrete Anwendungsszenarien, die sich natürlich je Nutzergruppe der Plattform – Betreiber der Maschine, Hersteller der Maschine, Service und Lieferant von Algorithmen zu Predictive Maintenance – unterscheiden werden.

Eine solche typische Situation aus **Sicht des Betreibers** wurde bereits weiter oben erwähnt: Es wird eine neue Maschine angeschafft, die man proaktiv warten möchte. Sie liefert seit ihrer Inbetriebnahme zwar kontinuierlich Sensor- und Maschinendaten. Um daraus lernen zu können, fehlt es an einer ausreichenden Anzahl Ereignisse wie z.B. Störungen, um damit Korrelationen zwischen diesen und den Maschinendaten suchen zu können. Für das Unternehmen als Betreiber der Maschine wäre es daher sehr hilfreich, von anderen Betreibern der gleichen Maschine Daten zu Ereignissen und Maschinendaten zu bekommen, um diese zusammen mit den Daten ihrer eigenen Maschine für Modellierungen nutzen zu können.

Aus **Sicht des Servicetechnikers** würde während der Wartung ein Zugriff auf Daten vorheriger Störungen, der Ursachen dafür und Maßnahmen zur Behebung sehr hilfreich sein, kann er doch damit auf Erfahrungen und Wissen zurückgreifen, das ihm sonst so nicht zur Verfügung steht.

Die Sicht des Maschinenherstellers: Hersteller können Daten von Maschinen ihrer Kunden z.B. zusammen mit Indikatoren für die Intensität der Nutzung der Maschine verwenden, um damit Produktverbesserungen voran zu treiben. Diese Szenarien sind nur einige wenige Beispiele von Anwendungsfällen für **Daten und Algorithmen als Wirtschaftsgut**, welche den mit Predictive Maintenance befassten Interessengruppen mit dem PlatonaM Ökosystem bereitgestellt werden sollen. In Tabelle 2 sind Anwendungsszenarien zusammengestellt, die aktuell bearbeitet werden. Die Ziffern in Spalte 2 beziehen sich auf die Datenquellen von Tabelle 1.

Tabelle 2: Anwendungsszenarien für Predictive Maintenance, die mit der PlatonaM-Plattform bereitgestellt werden sollen

Anwendungsszenario	erforderliche Daten
Predictive Maintenance über Ereigniszeitmodelle, RCM-Modelle	{1, 2, 3, (4 od. 5 od. 6)}
Wandlung von Störungsberichten in Daten und PM-Modelle	{1, 2, 3}
mobile Erfassung von Störungen durch Monteure vor Ort	{1, 2, 3}
Predictive Maintenance über Machine Learning Sensorik & Ereignisse	{1, 2, 3}
für Klassifikation	{7, 8, 9}
Produktverbesserungen & Produktinnovationen; RCM-Modelle	{1, 2, 3, (4 od. 5 od. 6)}
Prozessoptimierung im Instandhaltungsmanagement ; RCM-Modelle	{1, 2, 3, (4 od. 5 od. 6)}
Prozessoptimierung im Instandhaltungsmanagement (Shopfloor)	muss individuell definiert werden
Predictive Maintenance unter Nutzung von Maschinenmeldungen; RCM-Modelle	{{1, 2, 3, (4 od. 5 od. 6), 7}
Kostenoptimale Vorhaltung von Ersatzteilen; RCM-Modelle	{1, 2, 3, (4 od. 5 od. 6)}

7 Ausblick: Dynamische Wirtschaftlichkeitsbetrachtung durch Predictive Maintenance

Für einen ökonomisch sinnvollen Einsatz von Predictive Maintenance müssen die dafür notwendigen Aufwände in einem angemessenen Verhältnis zum Nutzen stehen. Es bedarf einer gezielten Auswahl an geeigneten Anwendungsszenarien, damit die wirtschaftlichen Chancen und Potenziale für Unternehmen die Kosten von Predictive Maintenance nicht übersteigen. Dabei sind auch die Implementierungskosten und Amortisationsdauer zu berücksichtigen. Durch das PlatonaM-Ökosystem sollen insbesondere für KMU Implementierungskosten in Grenzen gehalten werden.

Durch Predictive Maintenance kann die Planbarkeit von Instandhaltungsmaßnahmen gewonnen werden. Bisher reaktiv gehandhabte Störfälle können in präventive Wartungen überführt und Ausfallfolgekosten somit unmittelbar vermieden werden. Über die Vermeidung einer ungeplanten Maßnahme hinaus besteht ein wirtschaftliches Potenzial darin, Wartungszyklen an die gegenwärtigen Gegebenheiten anzupassen. Hier kann vor dem Hintergrund einer zu bewahrenden Auslastung eine bedarfsgerechte sowie zustandsorientierte Priorisierung einer Wartung erfolgen. Zur Bewertung der Amortisation ist das Einsparpotenzial, das mit der Umsetzung einhergeht, zu betrachten. Die Quantifizierung einer einzelnen Maßnahme ist in diesem Zusammenhang sowohl für die ökonomische Beurteilung zur Einführung der Strategie notwendig, als auch für die Terminierung einer solchen Maßnahme. Diese steht in einem zeitlichen Konflikt zur Durchführung eines Produktionsauftrags, sodass abzuwägen ist, ob das Risiko einer Störung den Wertschöpfungsbeitrag eines geplanten Bearbeitungsprozesses übersteigt. Insofern bedarf es einer für den Einzelfall individuellen Wirtschaftlichkeitsbetrachtung, bei der sich ein Produktionsauftrag und eine durch Predictive Maintenance prognostizierte Instandhaltungsmaßnahme gegenüberstehen. Die Besonderheit einer solchen Wirtschaftlichkeitsbetrachtung liegt in der mit der Ausfallprognose einhergehenden Dynamik begründet. Eine Modellierung der Verschleißkurve impliziert die Abhängigkeit der Ausfallwahrscheinlichkeit von der Zeit. Die dafür notwendigen Daten werden über die Algorithmen der PlatonaM-Plattform bereitgestellt, um daraus schließlich Risikomodelle zu berechnen. Insofern wird durch das PlatonaM-Ökosystem und dessen Services eine kontinuierliche sowie dynamische Betrachtung ermöglicht.

Für eine Wirtschaftlichkeitsbetrachtung potenzieller Handlungsalternativen reichen diese Daten und die Modelle der Plattform noch nicht aus. Den dynamischen Risikomodelle müssen die potenziell anfallenden Mehrkosten gegenübergestellt werden, die mit der Entscheidung zugunsten eines Produktions- oder eines Instandhaltungsauftrags einhergehen. Hierfür ist eine Betrachtung derjenigen Kosten notwendig, die mit der Entscheidung für eine Handlungsalternative einhergehen. Grundsätzlich bestehen zwei Handlungsoptionen: produzieren oder instandhalten.

Wird eine Entscheidung zugunsten des Produzierens getroffen, besteht die Möglichkeit eines Stillstands währenddessen. Für diesen Fall sind die potenziell anfallenden Mehrkosten durch eine Störung zu berücksichtigen. Diese lassen sich unter dem Begriff der schadensbedingten Stillstandskosten zusammenfassen. Im Fall eines auftretenden Maschinen- bzw. Anlagenausfalls können Kosten aufgrund einer Minderung der erbrachten Leistung und Qualität, sowie durch einen erhöhten Verbrauch von Arbeitszeit, Material, und Energie entstehen (Beckmann & Marx, 1994, S.34). Mithilfe der durch die prognostizierte Ausfallwahrscheinlichkeit gewichteten Ausfallfolgekosten kann der Erwartungswert berechnet werden, der der Handlungsalternative Produktionsauftrag zuzuordnen ist (Aha, 2013, S. 35).

Demgegenüber besteht die Möglichkeit, eine Instandhaltungsmaßnahme durchzuführen, womit allerdings die Verspätung eines Produktionsauftrags einhergehen kann. Dadurch entstehen sogenannte Schadenskosten, die einen Mittelwert, welcher sich aus Vertrags-

/Konventionalstrafen, Sanktionen, Schadensersatzforderungen und auftretenden Kosten aufgrund der Nichteinhaltung festgelegter Liefertermine zusammensetzt, darstellen (Beckmann & Marx, 1994, S.33). Neben den Schadenskosten entstehen ebenfalls Opportunitätskosten, die durch nicht erzielte Erlöse aufgrund ausbleibender Produktionsaufträge anfallen.

Die Besonderheit dabei liegt darin, dass hier der Erwartungswert mithilfe der Gewichtung durch die prognostizierte Ausfallwahrscheinlichkeit bestimmt wird. Dieser dynamische Wert wird im Rahmen des Verhandlungsprozesses den Mehrkosten durch einen verspäteten Liefertermin gegenübergestellt. Schließlich kann eine Entscheidung zugunsten der Option getroffen werden, die durch niedrigere Kosten ökonomisch sinnvoller ist. Damit soll es Unternehmen ermöglicht werden, mit diesem Service zur Wirtschaftlichkeitsprüfung verschiedene Anwendungsszenarien ökonomisch bewerten zu können.

Die für solche Betrachtungen notwendigen Informationen stellen jedoch höchst sensibles Firmenwissen dar. Trotz höchster Ansprüche des PlatonaM-Ökosystems an Business Privacy ist nicht zu erwarten, dass solche Informationen der Plattform durch Firmen anvertrauen werden, zumal die dafür erforderlichen Kostenpositionen vielfältig und meist nicht trivial aus den IT-Systemen von KMU zu ermitteln sind. Mithilfe des Forschungsprojekts PlatonaM soll schließlich ein Beitrag dahingehend geleistet werden, dass Unternehmen zusätzlich zu Daten, Modellen, Apps und Risikomodellen außerdem Entscheidungshilfen zur Verfügung gestellt bekommen, die wiederum auf interne Datenquellen zurückgreifen. Der beschriebene Planungsprozess ist als spezieller Service zur Wirtschaftlichkeitsprüfung zu verstehen, welcher als Schnittstelle zwischen Plattform und Shopfloor fungieren soll.

Danksagung

Diese Arbeit wurde teilweise durch Fördermittel des Bundesministeriums für Wirtschaft, Mittelstand und Energie (BMWi) für das PlatonaM-Projekt unter der Fördernummer 01MT19005A unterstützt.

Literaturverzeichnis

- Aha, U. (2013). Optimierung von Instandhaltungsstrategien bei unscharfen Eingangsdaten. Kassel: kassel university press GmbH.
- Beckmann, G. & Marx, D. (1994). Instandhaltung von Anlagen. Konzepte, Strategien, Planung. Leipzig, Stuttgart: Deutscher Verlag für Grundstoffindustrie.
- Bin, S., Westphal, P., Lehmann, J. & Ngonga-Ngomo, A-C. (2017). Implementing Scalable Structured Machine Learning for Big Data in the SAKE Project. Tagungsband *IEEE International Conference on Big Data (Big Data)* (S. 1400-1407). Boston, MA, USA: IEEE.
- Coleman, C., Damodaran, S., Chandramouli, M. & Deuel, E. (2017). Making maintenance smarter. Deloitte Insights. Retrieved Jul 05, 2019, from <https://www2.deloitte.com/insights/us/en/focus/industry-4-0/using-predictive-technologies-for-asset-maintenance.html>.
- Förster, F., Müller, D., Scholz, D., Michalik, A. & Kiebler, L. (2019). Integration of condition based maintenance orders into the decision-making of autonomous control methods. Tagungsband *52nd CIRP Conference on Manufacturing Systems* (216-221). Ljubljana, Slovenia.
- Merkt, O. (2019). On the Use of Predictive Models for Improving the Quality of Industrial Maintenance: An Analytical Literature Review of Maintenance Strategies. Tagungsband *14th Conference on Information Systems Management co-located with 14th Federated Conference on Computer Science and Information Systems*. Leipzig, Deutschland.

- Nagel, M. & Riedel, R. (2017). Steuerung von Produktionssystemen auf Basis bedarfsorientiert konfigurierbarer Datenbausteine. Tagungsband *TBI 2017. Tage des Betriebs- und Systemingenieurs*. Chemnitz, Deutschland.
- Nagel, M. & Riedel, R. (2018). Wahrscheinlichkeitsmodelle für die proaktive Wartung auf Basis flexibel konfigurierbarer Datenbausteine. Tagungsband 3. *Anwenderkonferenz Smart Maintenance für Smart Factories*. Dortmund, Deutschland.
- Otto, B., Lohmann, S., Steinbuß, S. & Teuscher, A. (2018). IDS Reference Architecture Model: Industrial Data Space (Version 2.0). Dortmund: International Data Spaces Association.
- Otto, B., Jürjens, J., Schon, J., Auer, S., Menz, N., Wenzel, S. & Cirullies, J. (2016). Industrial Data Space: Digitale Souveränität über Daten (White Paper). München: Fraunhofer-Gesellschaft.
- Reinhart, F. (2016): Industrial Data Science – Data Science in der industriellen Anwendung. *Industrie 4.0 Management*, 32, 27-30.
- Sweeney, L. (2002). k-anonymity: a model for protecting privacy. *International Journal on Uncertainty, Fuzziness and Knowledge-based Systems*, 10(5), 557-570