

Industrie 4.0

eBook



Predictive Maintenance: Schritt für Schritt zur vorausschauenden Wartung

Konsequente Realisierung des geschäftlichen Mehrwerts von
Industrie 4.0 – Von der Datenintegration zur präskriptiven Analytik

Powered by:



Inhalt

- 3** Der geschäftliche Nutzen einer Predictive Maintenance-Lösung
Industrie 4.0 und das Internet der Dinge – vorausschauende Wartung – Vorgehen – Vorteile in konkreten Zahlen
- 7** Daten sammeln und Transparenz schaffen
Datenidentifikation – Datenzugriff – Datenaustausch und -integration – Datennutzung
- 10** Daten analysieren, Anomalien erkennen
Vorverarbeitung von Daten – Messgrößen und Schlüsselindikatoren – statistische Prozesslenkung – Anomalieerkennung
- 13** Prädiktion und Fehleranalyse
Allgemeine Beschreibung – detaillierte Sicht – konkrete Nutzung und Nutzen
- 17** Ableitung von Aktionen
Fachliche Beurteilung – Handlungsfähigkeit – Handlungsoptimierung – Umsetzungslücke
- 20** Integration als Lösung – IBM PMQ
IBM Predictive Maintenance and Quality

Powered by:



IBM Deutschland GmbH
IBM-Allee 1
71139 Ehningen
Telefon +49 (0)7034 15-0
Fax +49 (0)7034 15-2734
E-Mail halloibm@de.ibm.com
Web www.ibm.com/de

Vogel IT-Medien GmbH
August-Wessels-Str. 27, 86156 Augsburg
Telefon +49 (0) 821/2177-0
E-Mail redaktion@storage-insider.de
Web www.Storage-Insider.de
Geschäftsführer: Werner Nieberle
Chefredakteur: Rainer Graefen, V.i.S.d.P.
Autor: Michael Matzer
Erscheinungstermin: Juli 2016
Titelbild: chombosan - Fotolia.com



Haftung: Für den Fall, dass Beiträge oder Informationen unzutreffend oder fehlerhaft sind, haftet der Verlag nur beim Nachweis grober Fahrlässigkeit. Für Beiträge, die namentlich gekennzeichnet sind, ist der jeweilige Autor verantwortlich.
Copyright: Vogel IT-Medien GmbH. Alle Rechte vorbehalten.
Nachdruck, digitale Verwendung jeder Art, Vervielfältigung nur mit schriftlicher Genehmigung der Redaktion.
Nachdruck und elektronische Nutzung: Wenn Sie Beiträge dieses eBooks für eigene Veröffentlichungen wie Sonderdrucke, Websites, sonstige elektronische Medien oder Kundenzeitschriften nutzen möchten, erhalten Sie Informationen sowie die erforderlichen Rechte über www.mycontentfactory.de.
Tel. +49 (0) 931/418-2786.



Der geschäftliche Nutzen einer Predictive Maintenance-Lösung

Das Internet der Dinge und Industrie 4.0 sind derzeit in aller Munde. Es gibt verschiedene Ansätze, um Mehrwert und bessere Geschäftsergebnisse im industriellen Bereich durch IT zu erzielen. Gemein ist ihnen: Die Ressource, die es auszunutzen gilt, sind die Daten, die von Geräten, Maschinen und Technikern erzeugt werden. Sie zu sammeln, zu integrieren, zu bereinigen und gezielt auszuwerten, erfordert in aller Regel einen mehrstufigen Prozess, der gut geplant sein will. Dieses eBook gibt Ihnen einen Leitfaden an die Hand, um den Weg durch diesen Prozess beschreiten zu können.

Produkt-Designer	Nutzen die Kunden die Produkte auf eine Art und Weise, an die wir selber nicht gedacht haben?
Betriebsingenieur	Funktioniert die Maschine/der Prozess so gut wie geplant?
Supply Chain Manager	Wie können wir die Lagerungskosten der Materialien verringern?
Produktionsteam	Wo/Wann haben wir am häufigsten Ausfälle bestimmter Assets/ Infrastrukturelemente ?
Qualitätskontrolleur	Wie spielen die komplexen Ursachen von Qualitätsproblemen zusammen?
Wartungsplanung	Wie kann ich Wartungspläne und Ressourceneinsatz optimieren ?
Anlagenbetreiber	Was sind die Hauptursachen für ungeplante Ausfallzeiten ?
Kundendienst	Was sind die wichtigsten Prädiktoren für Gewährleistungsansprüche ?
Reparaturteams	Was sind die optimalen Standorte und Mengen für Ersatzteile?
Risikomanager	Sind wir aufgrund von Vermögensausfällen, Rückrufaktionen und Kundenreklamationen in Gefahr ?

rung fragt deshalb die Leiter ihrer Fachabteilungen wie Produktion, Qualitätssicherung, Instandhaltung usw. immer häufiger:

„Wie effektiv nutzt ihr die Daten unserer Maschinen und Ereignisse?“

Häufig ist diese Nutzung noch sehr eingeschränkt. Eine Herausforderung besteht darin, dass schon das Sammeln und Zusammenführen dieser Maschinendaten vielfach noch nicht selbstverständlich ist. Dafür sind ent-

Die aktive Nutzung der Daten, die Unternehmen durch die Nutzung von Industrie 4.0-Ansätzen zugänglich werden, erlaubt es, neue Antworten auf altbekannte Fragen zu finden. (Bilder: IBM)

Industrie 4.0 und das Internet der Dinge

In einem Unternehmen, das Maschinen, Geräte und Einrichtungen nutzt, gibt es immer Verbesserungsbedarf und -möglichkeiten. Das intelligente Produktionsmanagement inklusive einer vorausschauenden Instandhaltung und Qualitätssicherung ist eine der intuitivsten Möglichkeiten, einen schnellen Mehrwert für das Unternehmen und dessen Kunden zu schaffen. Die Geschäftsfüh-

sprechend moderne vernetzte Maschinen oder auf älteren Geräten auch nachträglich installierte Sensoren und Auswertungsgeräte mit geeigneten Integrationslösungen vonnöten, die die Verbindung zu den Maschinen und Geräten herstellen. Diese Integrationslösungen – technisch auch als Middleware oder Bus-System bezeichnet – müssen in einer Vielzahl von Unternehmen für industrielle Anwendungen erst eingeführt werden. Dies ist aber der zwingende

erste Schritt in Richtung Industrie 4.0, Digitalisierung und digitaler Transformation. Damit befasst sich Kapitel 1.

Der zweite Schritt erzeugt bereits konkreten Wert – er besteht in der Sammlung, Integration und Analyse dieser Informationen. Hiermit wird Transparenz und Kontrolle über die aktuelle Situation möglich, der Nutzer erhält Informationen, ob Auffälligkeiten (Anomalien) oder gar Ausfälle aufgetreten sind, worin sie bestanden haben und insbesondere wie sie zu bewerten sind (siehe dazu Kapitel 2):

- temporär unkritisch,
- potenziell risikobehaftet und weiter zu beobachten oder gar
- umgehend zu beheben?

ren die IBM-Lösung PMQ und ihr Potenzial in diesem Themenfeld.

Vorausschauende Wartung

Vorausschauende Instandhaltung – Predictive Maintenance (PM) – ist ein Paradeanwendungsfall für Industrie 4.0. Sie zielt darauf ab, Probleme zu beheben, bevor sie entstehen. Vielerorts wird sie als einer der wichtigsten Faktoren für vorausschauende und vorbeugende Aktionen genannt, auch weil der Ausfall kritischer Infrastrukturen als eines der größten Risiken anzusehen ist.

PM hilft, die Verfügbarkeit dieser kritischen Infrastrukturen (Maschinen, Gebäude, Fahrzeuge – allgemein häufig als Assets bezeichnet) zu erhöhen, Produktionsstillstand zu vermeiden, die Lebensdauer einer Lokomotive zu verlängern oder den Werftaufenthalt eines Hochseeschiffes möglichst optimal zu nutzen.

Diese Vorteile illustrieren den Wert von Industrie 4.0 für die Industrieunternehmen, wie ihn auch Roland Berger in einer aktuellen Studie beschreibt: Es geht nicht länger nur um eine stärkere Automatisierung, es geht um den effektiveren Einsatz der Sachwerte und damit eine höhere Effizienz des eingesetzten Kapitals des jeweiligen Unternehmens (Roland Berger Strategy Consultants: „Die digitale Transformation der Industrie“, eine europäische Studie im Auftrag des BDI, 2015)

Aber auch der Endkunde profitiert: Höhere und planbarere Verfügbarkeit bedeutet häufig einen besseren Service für den Endkunden, beispielsweise verlässlichere Fahrpläne für Fahrgäste in der U-Bahn. Diese kann damit dann erneut auch die unternehmerischen Wettbewerbschancen erhöhen: Die verbesserte Pünktlichkeit eines solchen Transportmittels kann einen Wettbewerbsvorteil gegenüber konkurrierenden Transportmitteln, etwa dem Auto, schaffen. So ist es beispielsweise der

Der **Ausfall kritischer Infrastrukturen** wird als das **größte Risiko** bewertet. In einer Befragung nannten 40% der Führungskräfte den Ausfall kritischer Infrastrukturen als den **einflussreichsten Risikofaktor** auf den Unternehmensbetrieb.

Die Haltung der Hersteller gegenüber Wartung

ändert sich ebenfalls. Wartung (Maintenance) wird zunehmend als **strategische Unternehmensfunktion** statt als ein notwendiges Übel bewertet.

Quelle: Roland Berger Strategy Consultants 2014


Die Bedeutung des effektiven Managements kritischer Infrastrukturen nimmt zu – Ungeplante Ausfälle müssen minimiert werden, um bei steigender Dynamik und Unternehmens-übergreifender Vernetzung wettbewerbsfähig zu bleiben.

Bei zunehmend ausgereifteren Lösungen werden dann Daten eingesetzt, um folgende Fragen zu beantworten: „Was ist passiert und welche Ursachen sehen wir?“ sowie „Was wird voraussichtlich passieren und wie sollten wir bzw. unsere Kunden präventiv agieren, um Fehler erst gar nicht auftreten zu lassen?“ – darauf gehen die Kapitel 3 und 4 ein.

Die Kapitel 5 und 6 widmen sich dann der Ableitung konkreter Aktionen und illustrieren

spanischen Eisenbahngesellschaft RENFE gelungen, ihren Expresszug Velaro, der zwischen Madrid und Barcelona verkehrt, so attraktiv zu machen, dass inzwischen viele Fahrgäste den Zug dem Flugzeug vorziehen. Das wiederum kommt der wirtschaftlichen Bilanz von RENFE zugute.

„PM-Lösungen setzen an zwei wesentlichen Hebeln an: die Reduzierung von Kosten im Sinne von Maschinen-Wartungs- oder Reparaturkosten, aber auch die Vermeidung von Maschinenausfällen und von (ungeplanten) Maschinenstandzeiten im Produktionsprozess“, sagt IBM Senior Consultant Philipp Schalla. „Auch der Verbesserung der Durchlaufzeiten und -mengen sowie der allgemeinen Produktqualität gilt das Augenmerk der Fachbereiche.“



Kommerzielle und (Daten-)technische Sicht bedingen sich – Umsetzungsprojekte sollten auf eine klare Vision ausgerichtet sein, dann aber die konsequente und sukzessive Umsetzung von Teilerfolgen fokussieren.

Je bessere und feingranularere Informationen über eine Maschine (aktuelle Funktion, historische Daten) und deren beeinflussende Umfeldfaktoren (Wetter, Raumbedingungen, ...) vorliegen, umso konkreter kann der Ausfall einer Maschine und damit eine negative Auswirkung auf den Produktionsprozess verhindert werden. Das Internet der Dinge liefert mit der Anbindung von Sensorik an ein Analytik-gestütztes Backend-System (die diversen Server) die notwendige Grundlage für die Funktionsweise von PM-Systemen. Es soll hier gezeigt werden, dass vorausschauenden

de Wartung nicht als das ausschließliche Ziel missverstanden werden sollte. Bereits auf dem Weg zu ihrer Umsetzung können vielfältige Mehrwerte (sogenannte „quick wins“) erzeugt werden.

Vorgehen

Predictive Maintenance-Lösungen liefern den jeweiligen Fachabteilungen konkrete Mehrwerte; Pilot- und Einführungsprojekte werden daher auch typischerweise durch diese und selten durch die IT-Abteilungen initiiert.

Fachbereiche müssen im Sinne der Unternehmensstrategie wirtschaftliche Verbesserungen wie etwa erhöhte Qualität, verringerte Ausfallzeiten und längere Lebensdauer von teuren Maschinen erzielen und nutzen daher zunehmend und konsequent die neuen Möglichkeiten – auch weil traditionelle Ansätze bereits ausge-reizt oder vergleichsweise aufwendig sind. Eine gute Planung dieser Projekte ist essenziell, die Projektart und -methode unterscheidet sich aber ebenfalls vom häufig etablierten Weg, wie Dr. Holtmann, bei der IBM in Deutschland für das Thema verantwortlich, erläutert: Die Nutzungsvision – also die Antwort auf die Frage „Welchen konkreten Mehrwert werden uns Daten in 12, 24 oder 36 Monaten konkret liefern?“ – muss im Vordergrund stehen; dann werden allerdings typischerweise keine starren Projektpläne definiert, sondern kurzfristig angelegte, iterative Schritte auf Basis geeigneter Lösungen umgesetzt, um schnell konkreten Wert zu erzeugen und diesen gegenüber der Geschäftsführung nachweisen zu können.

Der Leitspruch „fail fast“ (scheitere schnell) erscheint auf den ersten Blick nicht intuitiv; er erlaubt es allerdings, schnell herauszufinden, wie in der jeweiligen Ausgangssituation mit möglichst geringem Aufwand die besten Ergebnisse erzielt werden können – so lassen sich die typischen Fehler von


Großprojekten vermeiden, Projektkosten werden im Rahmen gehalten, Actioned Insight entsteht. Die folgenden Kapitel konkretisieren dies im Einzelnen.

Vorteile in konkreten Zahlen

Das Energieministerium der Vereinigten Staaten hat die wirtschaftlichen Vorteile der Nutzung einer PM-Lösung für Betriebsoptimierung bereits 2010 formuliert. Für das Ministerium sind Wartung und Instandhaltung (Maintenance) nicht mehr nur unliebsame Kostenfaktoren, sondern von großer Bedeutung und werthaltig für die Vorstandsebene. „Die wirtschaftlichen Vorteile, die sich mit PM anhand von kostengünstigen Sensoren, fortschrittlicher Analytik und dem Internet der Dinge erzielen lassen, sind überraschend hoch: der zehnfache Kapitalrückfluss (1.000 Prozent ROI), 25 bis 35 Prozent weniger Wartungskosten, 70 bis 75 Prozent weniger Ausfälle, 35 bis 45 Prozent höhere Betriebsbereitschaftszeiten und 20 bis 25 Prozent Steigerung in der Produktion.“ (Zitiert nach: Cabot

Partners 2015: „Fast and reliable systems for highly accurate predictive maintenance and quality (PMQ)“)

Wettbewerbsvorteile wie etwa höhere Umsätze und bessere Qualität bei verbesserter Nutzung und Wartung von Ressourcen sind gute Gründe, um das Produktionsmanagement zu modernisieren, mit dem Ziel, vorausschauende Wartung konkret in Angriff zu nehmen und schrittweise in die Realität umzusetzen. Schrittweise ist dabei entscheidend, denn es wird in den folgenden Kapiteln deutlich werden, dass jede einzelne Entwicklungsstufe bereits konkreten Wert erzeugen kann und sogar muss, wie Dr. Holtmann deutlich unterstreicht.



Leistungsfähige Lösungen holen den Anwender ab, wo er ist, und bieten die Option, sukzessiver und nachhaltiger Verbesserung durch zunehmend leistungsfähige Ansätze.

Daten sammeln und Transparenz schaffen

Der erste Schritt besteht im Sammeln und Konsolidieren der Daten, die Anlagen und Infrastrukturen erzeugen. Zu diesen Informationen gehören Stammdaten wie Anlagen-Identifikationsnummern (Asset IDs) sowie Messwerte oder Statuscodes mit Zeitstempeln.

Datenidentifikation

Ausgangspunkt von PM-Lösungen sind jeweils die folgenden Fragen:

- Über welche Daten und Datenquellen verfügen wir?
- Wie machen wir sie nutzbar?
- Wie integrieren wir sie?
- Wie schaffen wir konkreten Mehrwert?

Diese Grunddaten zu sammeln und in ein geeignetes Werkzeug zur Speicherung und Visualisierung zu überführen, kann schon den ersten wesentlichen Mehrwert darstellen – Daten werden zentral speicher- und einsehbar, Datenverläufe transparent und vergleichbar, zeitliche Zusammenhänge im Auftreten bestimmter Stadien gegebenenfalls zum ersten Mal beobachtbar.


Welche Gegenstände, Anlagen oder Komponenten in Fertigung, Bergbau, Landwirtschaft oder Energieerzeugung überwacht werden, kann sehr unterschiedlich sein. Alle möglichen Anlagen sind denkbar, von Pumpaggregaten, Maschinen und Autos angefangen bis hin zu Kränen, LKWs und sogar ganzen Ölbohrplattformen. Selbstverständlich lassen sich auch andere Infrastrukturen wie Rechenzentren überwachen. Unterschiedlich sind die Herausforderungen bei der Erfassung und Verarbeitung der Daten: Typische Herausforderungen sind das Problem des Daten-Auslesens aufgrund uneinheitlicher technischer Schnittstellen und Protokolle (unterschiedliche Hersteller), unterschiedliche Frequenzen

(ein Messwert pro Stunde vs. Hunderte pro Sekunde), deren Übertragung aufgrund der Lage (Hochseeplattform) oder gar weil die Daten beweglich sind (Züge, Autos). Die schiere Datenmenge gehört ebenso dazu: Ein Flugzeug beispielsweise ist eine Extremform – ein Airbus A380 generiert pro Flug mehrere Dutzend Terabyte an Daten. Moderne Informationstechnologie bietet allerdings ebenso vielfältige Lösungsoptionen, um dieser Herausforderungen Herr zu werden; die eigentliche Herausforderung ist häufig die initial verfügbare Datenmenge und -qualität.

Datenzugriff

In der Regel erzeugen moderne Maschinen eine große Menge an Daten. Sie werden nur häufig noch nicht erfasst und zusammengeführt. In vielen Maschinen ist lediglich ein kleiner, lokaler Speicher vorhanden, der nach Stunden oder Tagen überschrieben wird, sofern ihn nicht ein angekoppeltes ICS-System (ICS: Industrial Control System) wie etwa SCADA (Supervisory Control and Data Acquisition) ausliest. Selbst bei einer längerfristigen Speicherung lässt sich oft die Information nicht einfach auslesen und weitergeben.

Häufig werden Maschinendaten am Bedienfeld und mit integriertem Monitor angezeigt. Ein Alarm erreicht den zuständigen Mitarbeiter vor Ort, der diesen sieht, handelt und abstellt. Fehler und Alarm sind



Beispiel des integrierten Produktions-Dashboards einer Stahlverarbeitung – Parameterüberwachung und Einstufung in Kritikalität (Bild: IBM)

behalten, die Information, dass ein Alarm vorlag, verschwindet indes häufig oder wird separat und manuell dokumentiert. Der Missstand, dass diese wertvolle Information die Maschine nicht verlässt oder nie in ein zentrales Datenhaltungssystem weitergeführt wird, isoliert dieses Ereignis und macht es nicht nur ärgerlich, sondern zudem – und das ist häufig als noch schlimmer zu beurteilen – „nutzlos“, weil Behebung nicht gleich Lernen und strukturelle Verbesserung einschließt. Der erste Schritt zur Verbesserung der Wartung sollte also in der zentralen, einheitlichen und vollständigen Datensammlung bestehen.

Wie lässt sich nun dieses Auslesen und Weiterleiten bewerkstelligen? Die Maschine könnte direkt mit Sensoren, welche die Zustände erfassen, versehen und einem Netzwerk verbunden werden, das die relevanten bzw. gewünschten Daten an ein zentrales System weiterleitet. Es existieren verschiedene Austausch- und Kommunikationsformate (Protokolle), mit deren Hilfe Maschinen nicht nur mit Zentralsystemen „sprechen“ können, sondern auch mit anderen Maschinen (M2M) und Dingen. Eines dieser Protokolle ist OPC-UA, aber es werden weitere, offene Protokolle entwickelt

und unterstützt. IBM treibt hierfür beispielsweise die Entwicklung des Protokolls MQTT voran.

Datenaustausch und -integration

Was zur Datenintegration benötigt wird, ist eine sogenannte Middleware, die als Integrationsebene oder auch „Bus“ fungiert, der als zentrale Verständigungsleitung dient. Das ist eine Kommunikationsebene, die dadurch geprägt

ist, dass sie Informationen entweder sehr schnell oder sehr strukturiert weiterverarbeiten kann und dass sie viele Schnittstellen und Konnektoren bieten kann, um verschiedene Maschinen, verschiedenartige Maschinentypen und unterschiedliche Kommunikationsprotokolle abzudecken. Damit werden Informationen erst einmal zusammengeführt, um sie gemeinsam verarbeiten und auf diese Weise übergreifende Messgrößen (KPI, Key Performance Indicators) berechnen zu können. Das entsprechende Werkzeug wendet dabei Regeln auf die Daten an, um sie zu „normalisieren“, zu filtern, weiterzuleiten und auszuwerten. Das zuständige Werkzeug für die Erstellung und Implementierung von Regeln für Betriebslogik ist eine Rules Engine. Sie ist häufig Teil des Integrationsbusses. (Mehr Details zu KPIs und Regeln finden Sie in den folgenden Kapiteln.) Daten sind nicht nur auf Maschinenebene zu integrieren, sondern auch aus unterschiedlichen IT-Systemen abzurufen, um beispielsweise Ursachen für bestimmte Betriebsvorgänge und Anomalien herauszufinden. Wenn ein Produktionsstillstand erfolgt ist, will der überwachende Mitarbeiter wissen, wann und vor allem wodurch dieser beendet wurde. Da es vorstellbar

ist, dass ein Mechaniker im Einsatz war, hilft meist ein Blick in das Instandhaltungs-Management-System.

Beide Informationen gilt es zu koppeln. Wie diese Kopplung erfolgt, lässt sich auf der Ebene der Regel-Logik und der Middleware des Integrationsbusses implementieren.

Mithilfe des Integrationsbusses erhält der Nutzer auf seiner hohen Ebene also eine große Flexibilität in seinem Bemühen, die gewünschten Informationen aus verschiedenen Maschinen zu holen. Er kann Informationen aus einem ERP-System, einem Asset-Management-System, der Stammdatenhaltung oder einem Produktionssteuerungssystem abrufen, um nur ein paar verbreitete Systeme zu nennen.

Datennutzung

Bei sehr großen Datenmengen – wir hatten das Beispiel des Flugzeugs erwähnt – kann es sinnvoller sein, nicht alle Daten erst einmal zusammenzuführen, um sie zu analysieren. Hier besteht die Möglichkeit, die Logik zu den Daten zu bringen statt umgekehrt. Wer die Daten bereits filtern kann, bevor sie zentral zusammengeführt werden, der hat es nur noch mit einem Bruchteil der ursprünglichen Datenmenge zu tun.

Der weitere Mehrwert einer datengetriebenen Transparenz wird schnell bei dezentraler Produktion deutlich, so etwa wenn zehn Maschinen in zehn internationalen Werken zu überwachen sind. Typische Fragen lauten hier: Sind die Maschinen einsatzfähig und betriebsbereit? Hat es eine Betriebsstörung oder Alarmmeldung gegeben?

Ein Fertigungsleiter, der Maschinen an verschiedenen Standorten zu verantworten hat, bekommt statt einer direkten Sensormeldung von der Maschine heute meist indirekte und zeitlich verzögerte Informationen: Abweichungen vom Produktionsziel pro Tag oder auch schriftliche Ausfallinformationen. Was häufig fehlt, sind Hintergrunddaten, die Details verdeutlichen, Ursachen erken-

nen lassen, warum es zu dem Ausfall kam und wie und von wem die Reparatur erfolgen konnte. Die zeitnahe Schlussfolgerung, ob bei gleichen Maschinen oder andersorts ggf. ein verbundenes Risiko existieren könnte oder ob durch Umplanung eventuell der Ausfall kompensiert werden könnte, ist damit schwierig. Zunehmend wichtige Themen wie Ausfallsicherheit, Liefertreue, Qualität könnten verbessert werden.


Zentrale Fertigungsleiter oder globale Produktionscontroller würden sehr davon profitieren, wenn sie integrierte Daten, zeitnahe Reports oder gar eine elektronische Visualisierung mittels Dashboard im Zugriff hätten, die ihnen die Maschinen-Informationen automatisch zur Verfügung stellen würden. Je aktueller, einheitlicher und integrierter diese Daten sind, desto nützlicher sind sie für die nachgeordneten Produktionsschritte oder die Steuerung.

Diese Granularität zu bekommen, die automatisch aus einer Infrastruktur erzeugt wird, bildet bereits einen ersten großen Mehrwert: Die manuelle Erfassung wird überflüssig und damit eine Fehlerquelle eliminiert. Maschinen-Informationen lassen sich standardisieren und direkt in Reports oder in ein Dashboard überführen, so dass überregional vergleichbare – also auch einheitlich interpretierbare – und stets aktuelle Daten zur Verfügung stehen.

Wieviel Wert steckt aber letztlich in diesen Monitoring-Daten? Wie so häufig „kommt es darauf an“: Für Qualitätsdokumentationen sind unter Umständen standardisiert erzeugte, hochgranulare Detaildaten von direktem Nutzen, geht es aber um die Produktionssteuerung und das Thema vorausschauende Wartung, dann ist meist weniger die Menge der Informationen wertvoll – hier sind eher die Ausreißer, die Anomalien relevant, die Hinweise darauf geben, wo eventuell dringend Aufmerksamkeit notwendig ist und konkreter Handlungsbedarf besteht.

Daten analysieren, Anomalien erkennen

In Kapitel 1 war bereits die Rede von Sensordaten und Alarmmeldungen, die an einer Maschine angezeigt, aber häufig nicht weitergeleitet werden. Der Schritt im Reifungsprozess nach der Integration und dem Monitoring dieser maschinellen Datenquellen ist die Anwendung von fortgeschrittenen Analyseverfahren (Advanced Analytics) auf diesen Daten. Hierfür ist es jedoch zunächst erforderlich, die Daten zu vereinheitlichen und vorzuverarbeiten.



Beispiel des integrierten Produktions-Dashboards einer Stahlverarbeitung – Parameterüberwachung und Aggregation in einen „Gesundheitswert“ (Health Score) (Bilder: IBM)

Im Anschluss an die Erfassung können die gesammelten Daten zu Kennzahlen bzw. Key Performance Indicators (KPIs) aggregiert werden, wie etwa die Gesamtverfügbarkeit einer bestimmten Anlage, und mit Hilfe von Methoden der statistischen Prozesslenkung überwacht werden. Auf der anderen Seite ermöglichen es Methoden aus dem maschinellen Lernen, bisher unbekannte Muster in Daten zu finden

und schließlich Ereignisse vorherzusagen. Ein Unternehmen sollte sich über die hier skizzierten Reifephasen sukzessive voran arbeiten:


- vom rein reaktiven Schritt „Ausfall und Reparatur“
- über präventive Instandhaltung (basierend auf Herstellerangaben und Prüfplänen bis zu Erfahrungen aus dem Betrieb)
- hin zu Bedingungs-basierter Instandhaltung (laufende Überwachung mit Sensorik usw.)
- und schließlich prädiktiver Instandhaltung (PM).

PM heißt damit häufig, sich auf eine Reise sukzessiver Verbesserung zu machen. Die Fachbereiche eines Unternehmens können und sollten in jedem einzelnen PM-Schritt konkreten Mehrwert erzeugen und so sicherstellen, dass jeweils ein Business-Effekt erzielt wird:

- bessere Fehlererkennung durch Transparenz,
- schnellere Fehlerbehebung durch Anomalieerkennung,
- Fehlervermeidung durch vorausschauende Planung und
- detailliertere Fehleranalyse, Entscheidungsoptimierung auch bei zunehmend komplexen Rahmenbedingungen.

Der Erfolg muss und wird sich in Kostenreduktion, höherer Servicequalität, zufriedeneren Kunden und Partnern oder Gewinnsteigerungen messen lassen. Auf diese Weise kann sich ein PM-Projekt von Schritt zu Schritt selbst finanzieren. Teilweise entstehen dadurch auch ganz neue Produkte – wenn Unternehmen diese Funktionen in ihre eigenen Maschinen mit einbetten.

Starten wir Schritt für Schritt.



Beispiel des integrierten Produktions-Dashboards einer Stahlverarbeitung – Heat Map einer Anomalieerkennung und Anomalie-details

Vorverarbeitung von Daten

Ein Anwender muss Daten erst einmal zur Verfügung haben, um überhaupt die Visualisierung von einheitlichen Metriken erzeugen zu können. Es sind also Maschinendaten zu erfassen und zu aggregieren – siehe Kapitel 1. Die anschließende Vereinheitlichung dieser Messwerte ist ein wesentlicher Punkt im Prozess der Vorverarbeitung. Man will ja nicht Äpfel mit Birnen vergleichen. Auch wenn hierbei Werkzeuge und vorkonfigurierte Adapter helfen können, ist der Aufwand für die Vorverarbeitung von Daten nicht zu unterschätzen.

In Maschinenparks und in ganzen Werken werden bereits heute Messgrößen (Metriken) für die Geräte angewandt. Das erste Problem ist dabei die Verschiedenartigkeit der Maschinentypen. Jede Maschine hat eine andere Logik, mit der sie Fehler erkennt oder Fehler beurteilt. Die eine gibt einen Alarm bei 10°C, die andere gibt ihn bei 12°C, die nächste gibt ihn erst bei 14°C. Eine vierte Maschine gibt überhaupt keine Alarme bei Temperaturüberschreitungen, sondern hat vielleicht eine ganz andere Auslöselogik – Vorverarbeitung besteht daher in Zusammenführung und Vereinheitlichung.

Die interne Logik der Fehlererkennung in einer Maschine muss bei der Erfassung ihrer Daten berücksichtigt werden. Die Frage ist zum Beispiel, ob der jeweilige Schwellenwert bezüglich der Temperatur mit der KPI-Vorgabe übereinstimmt oder wie weit er davon abweicht – und ob diese Abweichung signifikant genug ist, um einen Alarm auszulösen.

Messgrößen und Schlüsselindikatoren

In jedem Bewertungsvorgang für Störungen im Betriebsablauf ist ein Soll-Wert mit einem Ist-Wert zu vergleichen. Der Soll-Wert ergibt sich aus Vorgaben bestimmter Kenngrößen: den Schlüsselindikatoren. Aktuelle Daten werden dafür mit historischen Daten verglichen.

Ein Ziel könnte es beispielsweise sein, die Verfügbarkeit einer Infrastruktur oder einer Maschine (Lokomotive, Flugzeug usw.) zu messen. Erst wenn man diesen Wert laufend in Echtzeit messen und anhand der Korrelation mit KPIs bewerten kann, weiß der Anwender, in welchem Zustand sich die überwachte Ressource befindet, und kann entsprechend darauf reagieren. Ist der Zustand besorgniserregend und wird ein Alarm ausgelöst? Dann muss der KPI-Wert deutlich über- oder unterschritten

worden sein, falls es nicht gleich zu einem Ausfall gekommen ist.

Statistische Prozesslenkung

Um einzelne Messwerte zu analysieren und Übertritte über Schwellwerte erkennen zu können, bietet es sich darüber hinaus an, statistische Werkzeuge zu verwenden. Im ersten Schritt sind typischerweise relativ einfache Visualisierungen möglich, so dass der Nutzer bestimmen kann, welchen Datenfluss er ansehen möchte. Dann legt er die Parameter für Zeitpunkt und Dauer fest. Er hat die Möglichkeit, diesen Datenfluss in einer Art „Korridor“ zu filtern. Dieser Korridor oder Trichter besteht aus den unteren und oberen Schwellenwerten für einen Messwert bei einem bestimmten Typ von Maschine. Dieser Korridor kann über eine Darstellung der Standardabweichung automatisch berechnet werden – die resultierenden Visualisierungen sind als SPC-Charts (Statistical Process Control) bekannt.

Anomalieerkennung

Den ersten Schritt in Richtung Anwendung von maschinellem Lernen – Details dazu folgen noch – auf Mess- und Alarmdaten bildet die Anomalieerkennung. Die Anomalieerkennung gehört zu den Verfahren des sogenannten unüberwachten Lernens, was ihre Anwendung wesentlich einfacher als andere Verfahren macht und daher einen guten Einstieg bildet. Unüberwachtes Lernen bedeutet, dass ohne Hinterlegen von Annahmen oder Hypothesen Muster in Daten automatisiert erkannt werden.

Der Normbereich und die kritischen Zustände werden auf Basis von historischen Daten automatisiert erkannt. So lernt ein Werkzeug für die Anomalieerkennung aus historischen Daten, dass Temperatur und Drehzahl eines Elektromotors miteinander gleichmäßig ansteigen und abfallen. Wenn nun der Elektromotor defekt ist, kann die

Temperaturentwicklung deutlich höher als im Normalbereich bei gleicher Drehzahl liegen.

Dies wird als Anomalie identifiziert, indem man multivariate – also unterschiedliche Einflussgrößen überwachende – Verfahren zur Anomalieerkennung anwendet. Betrachtet man nur zwei Messpunkte, wird jeder Mensch in der Lage sein, diese Anomalie ebenfalls zu erkennen. Wenn man indes die Datenmassen betrachtet, welche im Kontext von Industrie 4.0 anfallen, bedarf es moderner Werkzeuge zur Anomalieerkennung, um hier noch den Überblick zu behalten.

Prädiktion und Fehleranalyse

Der Nutzer in einer Fachabteilung möchte typischerweise nicht nur wissen, wo Anomalien in der Vergangenheit aufgetreten sind, sondern auch, wie er solche Anomalien vorhersagen kann. In Reports und Dashboards hat er gesehen, wo und wann Störungen auftraten, aber er kennt noch nicht die Ursachen dafür – und er will sie, um den größten Vorteil zu erzielen, künftig vor deren Auftreten vermeiden. Für beide Ziele ist es notwendig, prädiktive (statistische) Modelle zu entwickeln – und zwar für jede einzelne Anlage, ganz gleich, ob es sich dabei um eine Ölbohrplattform handelt oder um eine Druckmaschine.

Allgemeine Beschreibung

Das Problem besteht darin, dass zwei scheinbar ähnliche Werkstücke, die an verschiedenen Tagen unter unterschiedlichen Bedingungen hergestellt wurden, verschiedenartige Betriebsmerkmale aufweisen und dementsprechend abweichende Wartungshistorien gespeichert haben, sobald sie unter abweichenden Umweltbedingungen, Lasten und Betriebsumständen genutzt wurden.

Jeweils ein prädiktives Modell muss also für jeden Typ von Asset (Komponente, Maschine, Anlage) angefertigt werden, die es zu überwachen gilt. Ein prädiktives Modell erkennt die Muster in den Daten aus Sensoren, CNC- oder MES-Systemen (MES: Manufacturing Execution System) und ihre Beziehung zu Ausfällen von Assets. Das Modell berechnet die angemessenen und erlaubten Betriebsbeziehungen unter allen relevanten Parametern, wie etwa Last, Temperatur, Druck, Schwingung, Feuchtigkeit usw. Diese KPIs entsprechen den jeweiligen Soll-Werten. Das Modell vergleicht diese Vorgaben mit tatsächlichen

Echtzeitableasureungen von Messpunkten und vergleicht sie mit der „normalen“ Reaktion dieser bestimmten Maschine oder Anlage. Es ergeben sich immer Unterschiede zwischen Soll- und Ist-Wert. Aufgrund der Unterschiede zwischen der Echtzeitmessung und dem Normverhalten sowie deren Dauer entdeckt und isoliert die PMQ-Lösung anomales Verhalten im Rahmen der Betriebsbedingungen. Die Lösung versendet ihre Entdeckungen über Anomalien und erstellt bereits Benachrichtigungen sich entwickelnder Probleme an die Nutzer. Diese Vergleiche und Neuberechnungen sowie Meldungen erfolgen automatisch, fortwährend und konstant rund um die Uhr.

Es wäre indes von großem Vorteil, wenn dieser mühselige Vorgang so gut wie möglich beschleunigt werden könnte. Ein vermiedener Ausfall ist gewonnener Profit, je früher Anomalien möglichst konkret prognostiziert werden können, desto länger ist die Vorlaufzeit für die vorausseilende Korrektur. Zeitlicher Vorlauf und Prognosegüte sind entscheidende Qualitätsindikatoren für die eingesetzten Modelle.

Wie die Lösung einen Schritt weitergehen und Handlungsempfehlungen geben kann, wird in Kapitel 4 erläutert.


Detailliertere Sicht

Oben wurde die Erstellung eines Modells lediglich grob skizziert, lassen Sie uns etwas konkreter in die Details schauen: Die Maschinendaten ergeben einen Datenpool, den es auszuwerten gilt. Im ersten Schritt trennt man den Datenbestand zufällig in zwei Pools, in einen Trainings-

Auswahlkriterium für die Methode sein. Ein anderes kann darin bestehen, dass die Visualisierung des gefundenen Zusammenhangs für den Endbenutzer möglichst intuitiv verständlich ist. Ein illustratives Verfahren zur Fehleranalyse ist mitunter die Analyse eines sogenannten „Entscheidungsbaums“. Moderne Verfahren zur Berechnung eines Entscheidungsbaumes erkennen automatisiert die Strukturen in Fehlern, also die Abhängigkeiten mehrerer Parameter und deren Wechselwirkung. Die Suche gilt demjenigen Fehlerfaktor mit dem größten Einfluss. Möchte man etwa den Omnibus-Verkehrsdienst optimieren, könnte sich die Zeit als größte Einflussgröße herausstellen, als die zweithäufigste der Wochentag und als dritthäufigste das Wetter.

Diesen Baum würde die Software aufgrund der Trainings-Daten (TDB) eigenständig aufbauen. Sie liefert dem Nutzer nicht nur die Ebenen der wichtigsten Einflussfaktoren, sondern auch mehrere „Wurzelknoten“ auf der gleichen Ebene. Die Software würde quasi sagen: „Zwischen 7:30 und 8:30 haben wir den stärksten Einfluss der Tageszeit auf die Wartezeit der Fahrgäste.“ Kein Wunder, denn es ist die Rush Hour. Dies wäre also eine einfach gefundene Fehlerursache (Root Cause).

Entscheidungsbäume können also eine leicht interpretierbare Form einer solchen Fehleranalyse sein. Der Vorteil: Der Fachexperte kann die gefundenen Zusammenhänge leicht nachvollziehen und mit seinem Expertenwissen vergleichen. Vielfach zeigt sich, dass die gefundenen Zusammenhänge das widerspiegeln, was erfahrene Experten als Bauchgefühl haben. Die Explizierung und Konkretisierung, vor allem aber auch die Möglichkeit zur Weitergabe und die exakte Vergleichbarkeit stellen aber einen zusätzlichen Wert dar. Fortgeschrittenere statistische Methoden sind beispielsweise neuronale Netze. In



Beispiel des integrierten Produktions-Dashboards einer Stahlverarbeitung – Fehlerprognose auf Maschinen- und Komponentenebene mit Entwicklung über die Zeit (Bilder: IBM)

Datenbestand (TDB) und einen Kontroll-Datenbestand (KDB). Mit dem TDB trainiert man sein Modell in einem Statistikprogramm wie dem IBM SPSS Modeler, um in der Designphase Muster zu erkennen. Dies geschieht, indem man verschiedene statistische Methoden darauf anwendet. Man prüft die statistische Genauigkeit dieser Mustererkennung und der daraus abgeleiteten Prognosen.

Der Model-Designer – häufig als Data Analyst oder Data Scientist bezeichnet – ist bestrebt, die Methode zu finden, die beispielsweise den genauesten statistischen Zusammenhang liefert. Exaktheit kann ein

diesem Zusammenhang spricht man dann auch von Data Mining, ein Schlagwort, das heute in aller Munde ist. In dieser Richtung gelangt man dann in den Bereich der kognitiven Lösungen. Unter diesen hat IBM Watson einen hohen Bekanntheitsgrad erlangt, da Watson in der Quiz-Sendung „Jeopardy!“ gegen menschliche Kontrahenten bei der in natürlicher Sprache formulierten Beantwortung von Fragen triumphieren konnte – es handelt sich also um eine sehr weit entwickelte Lösung, die aber im Kern auf statistischen Verfahren aufsetzt, die als Services nutzbar sind.

Zu unterscheiden sind zwei Phasen beim Data-Mining: die Trainingsphase der prädiktiven Modelle und das sogenannte Scoring, bei dem konkrete Voraussagen berechnet werden. In der Trainingsphase werden historische Daten analysiert; je

umfangreicher und länger eine konsistente Historie zurückreicht, umso besser. Das Training der prädiktiven Modelle kann bei großen Datenmengen sehr viel Rechenleistung in Anspruch nehmen, weshalb moderne Softwarelösungen eine entsprechende Skalierbarkeit realisieren müssen. Beim Scoring erfolgt die Anwendung dieser prädiktiven Modelle auf den konkreten Anwendungsfall: Liegt bei diesem Asset eine Anomalie vor? Wie hoch ist die Wahrscheinlichkeit eines Ausfalls dieses Assets?


Die Beantwortung dieser Fragestellung erfolgt auf Grundlage des zuvor berechneten prädiktiven Modells.

Exkurs: Extremfall Edge Analytik

Im Zusammenhang mit Modellen und ihrer Mustererkennung stellt sich häufig das Problem des Datenvolumens. So etwa bei

der Anwendung auf eine Ölbohrplattform. Sie erzeugt ungeheure Mengen an Daten, deren Handhabung nicht banal ist. Wenn etwa der Bruch eines Bohrers prognostiziert werden soll, dann würde sich der lokale Manager weigern, diese Datenmengen an ein zentrales System, etwa in Hamburg, zu senden: Das ist einfach nicht machbar. Der übliche Ansatz, die Daten zum Algorithmus oder zum Modell zu bringen, funktioniert nicht.

Man dreht deshalb den üblichen Ansatz um und bringt das Modell zu den Daten, quasi an den Rand des



Beispiel des integrierten Produktions-Dashboards einer Stahlverarbeitung – Aus historischen Daten automatisch erzeugter Fehlerbaum: Welche Einflussfaktoren führen mit welchen Häufigkeiten und unter welchen Parameterwerten zu erhöhtem Ausschuss?

Nutzungsbereich, daher der Begriff „Edge Analytik“ oder „Edge Technologie“. Konkret im PMQ-Kontext nutzen Fachleute mitunter eine kleine Rechner-Box. Auf diese Box wird das Modell aufgespielt und vor Ort transportiert und angeschlossen. Alle Daten der Ölbohrplattform, die man nutzen will, brauchen nur zu dieser Box zu laufen. Darauf wird die Auswertung vorgenommen und schließlich die Entscheidung hinsichtlich des Bohrerbruchs getroffen. An ein Zentralsystem, das die weitere Auswertung vornimmt, müssen dann nur noch ein Hundertstel, ein Tausendstel, ein Zehntausendstel weitergegeben werden. Dadurch gewinnt man sehr viel Effizienz hinsichtlich der Datenübertragung, aber auch eine schnellere Reaktionsgeschwindigkeit. Es kann also möglich und sinnvoll sein, das Scoring direkt bei der Maschine durchzuführen, um so wie oben beschrieben, Daten direkt vor Ort und ohne Zentralisierung zu nutzen und damit auch die Reaktionsgeschwindigkeit auf ein Minimum zu reduzieren.

Konkrete Nutzung und Nutzen

Nun verfügt der Nutzer über eine (mitunter kombinierte) Methode und hat ein Modell auf seine Trainingsdaten angewandt, um mögliche Zusammenhänge zu identifizieren. Diese Zusammenhänge wendet der Nutzer im zweiten Schritt auf seinen Kontrolldatenbestand (KDB) an, den er vorher isoliert hatte. Er weiß also: Die Modelle kennen diese neuen Daten nicht. Mit der Anwendung der ausgewählten Methoden bzw. den erzeugten Modellen auf diese neuen Daten prüft er also deren Prognosegüte.

Am Beispiel illustriert: Die Fachleute eines Kunden stellten Experten einen Trainingsdatensatz zur Verfügung und behielten den Testdatensatz zurück. Sie bekamen dann die von den Experten entwickelte Methoden und Modelle, um diese auf den Testda-

tensatz anzuwenden. Als Gütekriterium für eine erfolgreiche Projektbeurteilung wurde vereinbart, dass mindestens 75 Prozent aller Ausfälle – in dem Fall waren es Lokomotiven – vorausgesagt werden sollten. Die Experten waren in der Lage, 92 Prozent aller Zugausfälle zu antizipieren.

Das erstellte und erprobte Modell muss nun in laufende Prozesse eingebettet werden, etwa in ein Prozess-Steuerungssystem oder ein Monitoring-System. Das ist ein entscheidender Faktor, denn erst die Anwendung kann natürlich konkrete Mehrwerte liefern. Die Daten, die ab diesem Zeitpunkt aus der jeweiligen Maschine erzeugt werden, werden nun kontinuierlich von den Modellen überwacht, um Alarmierungen oder Nothalte auszulösen oder eben frühzeitige Wartungsaktionen anzustoßen.

Dieser Einblick hilft der Fachabteilung, die Ursachen für die Ausfälle, Abweichungen oder Defekte abzustellen. Dadurch ergeben sich Vorteile wie erhöhte Einsatzfähigkeit und Qualität des Geräts bzw. der Produktion, niedrigere Garantieansprüche seitens der Kunden und niedrigere Betriebskosten. Auch erhöhte und garantierte Verfügbarkeit ist ein wirtschaftlicher Service-Vorteil, der zu einer Erhöhung der Attraktivität dieses Services (Transport usw.) verhilft. In diesem Schritt lassen sich Ausfälle und Defekte vorhersagen, aber es gibt noch keine spezifische Handlungsweise, die empfohlen worden ist. Diese nach Dringlichkeit empfohlenen „next best actions“ werden im nächsten Kapitel vorgestellt. Heute nutzen bereits Early Adopters in den Branchen Fertigung, Energie, Transport und IT diese Technologie.

Ableitung von Aktionen

Nachdem der Benutzer Zusammenhänge zwischen Anomalien entdeckt und sogar Fehlerursachen eruiert hat, steht er vor der Entscheidung, welche Handlung die richtige ist, um die Folgen der Anomalien zu beseitigen und die Ursachen zu bekämpfen.

Dabei stellen sich weiterführende Herausforderungen, denn es gibt viele Muster und Handlungsoptionen:

- Welche sind fachlich richtig?
- Welche sind relevant?
- Welche sind richtig bei komplexen Rahmenbedingungen?
- Welche sind leicht umgesetzt?

Fachliche Beurteilung

Wann immer ein Nutzer Analytik und Statistik anwendet, wird er Zusammenhänge finden. Es werden immer Muster erkannt werden, die real in den Daten vorhanden sind, die aus fachlicher Sicht aber nicht notwendigerweise einen Sinn ergeben – anders formuliert und viel zitiert: „Korrelation bedeutet nicht zwangsläufig Kausalität“.

Die Schlussfolgerung lautet damit: Datenanalyse kann – wie bereits illustriert – latent bekannte Phänomene („Bauchgefühl“) untermauern und explizit machen, sie kann beispielsweise über Data Mining auch bislang unbekannte Phänomene und Abhängigkeiten zu Tage fördern. Ein blindes Vertrauen darf ihr aber nicht entgegengebracht werden. Vielmehr sind die Ergebnisse jeweils durch Fachexperten kritisch zu beurteilen, bevor konkrete Handlungsanweisungen abgeleitet werden.

Handlungsfähigkeit

Die zweite Herausforderung, der zu begegnen ist, ist die der Handlungsfähigkeit.

Reine Erkenntnis ist nicht nützlich, solange sie nicht in Aktion umgesetzt werden kann. Anders formuliert: Man muss sich auf solche Erkenntnisse fokussieren, die kommerziell relevante Handlungsoptionen eröffnen. Auf Neudeutsch heißt das „Actionable Insights“.

Wenn einem Werksleiter die Erkenntnis präsentiert wird, dass seine Maschinenausfallzeit vom Sonnenstand abhängt, ist das zwar eine interessante Erkenntnis, aber solange er nicht einen Weg findet, daran etwas zu verändern, hilft ihm dieser Zusammenhang wenig, denn er kann ihn nicht korrigieren. Er kann die Erkenntnis nicht in eine Aktion umsetzen. Damit ist die Erkenntnis interessant, aber praktisch wertlos. Ebenso ist eine Erkenntnis wertlos, deren monetäres Potenzial geringer ist als der Aufwand, der zur Behebung des Problems notwendig ist. Während die Aufwandseite schwer zu antizipieren ist, das Potenzial ist es durchaus. Und so kommt auch der Auswahl der richtigen Problemstellungen eine wichtige Bedeutung zu.

Man braucht also nicht nur „Insight“, sondern „Actionable Insight“. Der Nutzer muss zu einer Erkenntnis kommen, die er auch beeinflussen kann. Er sollte diese Erkenntnis in einen Prozess einbetten, etwa indem er eine Regel implementiert, dass bei einer bestimmten Temperatur eine bestimmte Aktion erfolgen soll. Im Fall der zu großen Hitze könnte dies in der Beschaffung eines Kühlaggregats bestehen.

Handlungsoptimierung


In den vorherigen Darstellungen haben wir bislang von zwei Stufen analytischer Reife gesprochen: a) der ersten Stufe, der deskriptiven (beschreibenden) Analytik, die jeweils rückwärts gerichtet ist und auswertende Betrachtungen erzeugt, die Transparenz schaffen; b) der zweiten Stufe, der prädiktiven (vorhersagenden) Analytik, bei der zwar auch historische Daten genutzt werden, aber nicht, um diese anzuzeigen, sondern um Zusammenhänge zu erkennen und Modelle und Prognosen abzuleiten. Eine dritte Stufe ist nun die präskriptive (vorschreibende) Analytik: Diese dient dazu, zwischen verschiedenen möglichen Zukunftszuständen diejenige Aktion auszuwählen, die für die jeweilige Situation des Anwenders am sinnvollsten ist. (Mathematisch ausgedrückt optimiert man damit eine Zielfunktion unter der Berücksichtigung von Nebenbedingungen.) Praktisch kann das heißen, dass ein Modell die „Wartungskosten einer Maschine“ minimiert, und dabei die Rahmenbedin-

gungen „rechtlich vorgeschriebene Mindestwartungen“, „Verfügbarkeit“ berücksichtigt. Softwarelösungen prognostizieren bei der präskriptiven Analytik verschiedene Umweltzustände, die auftreten können, und liefern dem Nutzer den konkreten besten Handlungsvorschlag, die „next best action“ – dem Optimierungsmodell müssen Informationen bereitgestellt werden, auf welches Ziel hin eine Entscheidung optimiert werden soll, und welche Nebenbedingungen beachtet werden müssen. Um noch einmal das Beispiel der Omnibusse aufzugreifen: Man möchte die Wartezeiten der Fahrgäste an den Haltestellen minimieren. Doch jetzt gibt es einschränkende Bedingungen: Erstens lassen sich nicht mehr als hundert Busse einsetzen. Zweitens darf die Taktung der Busse nicht schneller als 15 Minuten sein. Solche Randbedingungen und Optimierungsmodelle kennt der IT-Nutzer aus der Disziplin der Operations Research, von Simplex-Algorithmen, aus der linearen Optimierung usw. Mit dieser Art von mathematischer

Formulierung, einem Algorithmus, kann der Nutzer diese Optimierung erreichen.

Umsetzungslücke

Eines der intuitiv banalsten, in der Realität aber noch immer sehr häufig anzutreffenden Probleme: die fehlende Nutzung der Erkenntnisse. Viele Unternehmen haben sich dem Thema Analytics bereits genähert, viele in sogenannte Proof of Concepts (PoCs) mit dem einen oder anderen Dienstleister investiert.



Beispiel des integrierten Produktions-Dashboards einer Stahlverarbeitung – Konkrete Wartungsvorschläge für vier ausgewählte Maschinen und Möglichkeit zum Anstoßen einer Arbeitsanweisung (Work Order) (Bild: IBM)

Erschreckend ist, wie wenige der dabei entstandenen Erkenntnisse tatsächlich in Systeme, Prozesse, Handlungen umgesetzt werden. Viele scheitern sicherlich, weil eine der drei zuvor genannten Herausforderungen nicht richtig gehandhabt wurde, viele aber auch, weil die eingesetzte softwaretechnische Lösung oder der unterstützende Dienstleister schlicht nicht dazu in der Lage waren.

Auf der Softwareseite spielt bei der industriellen Problemlösung eben nicht nur die analytische Komponente, die Möglichkeit zur Datenintegration oder die der Visualisierung eine Rolle. Alle Elemente müssen vielmehr gleichermaßen vorhanden sein, um – je nach Anwendungsfokus und Reifestufe – eine umfassende Umsetzung zu erlauben. Der Benutzer, der von der Software Handlungsempfehlungen für die Gegenwart und die Zukunft erhalten hat, will korrigierende Aktionen anstoßen, beispielsweise einen Techniker an den konkreten Einsatzort schicken, um konkrete Wartungsarbeiten vorzunehmen, indem er direkt aus seinem überwachenden, analytischen Dashboard, dem Leitstand, heraus Arbeitsanweisungen abschickt. Auch die Integrationsfähigkeit der Lösungen mit eventuell vorhandenen Asset Management-Systemen, mit mobilen Endgeräten usw. spielt also eine Rolle.

Auf der Dienstleisterseite gilt entsprechendes: Ein Pool von exzellenten Statistikern oder Data Scientists ist extrem wertvoll und bei der aktuellen Nachfrage entsprechend kostspielig; doch für die Umsetzung der hier dargestellten Reifestufen von analytischen Lösungen bis hin zur Predictive Maintenance ist es nicht ausreichend, wenn nicht gleichzeitig entsprechende Beratungs-, Systemintegrations- und Konfigurationskompetenzen vertreten sind. Entscheidend – und das wird häufig unterschätzt – ist die Kompetenz, mit dem Kunden Wandel und Transformation zu gestalten,

denn Actioned Insight wird erreicht, wenn die entsprechenden Lösungen sinnvoll umgesetzt, vor allem aber von den Individuen beim Kunden auch aktiv genutzt werden.


Integration als Lösung – IBM PMQ

IBM hat sich vor Jahren entschieden, einen besonderen Schwerpunkt im Bereich der Analytik zu legen – mit strategischen Akquisen von führenden Produkten wie Cognos, SPSS und iLOG/CPLEX ebenso wie mit dem massiven Investment in die eigene Forschung und Entwicklung, die zuletzt mit WATSON die wohl derzeit umfassendste kognitive Lösung hervorgebracht hat.

Die Anwendung im Bereich industrieller Herausforderungen stellt einen besonderen Schwerpunkt dar und wird mit der integrierten Lösung „Predictive Maintenance and Quality“ (PMQ) adressiert.

Die aktuelle Version von IBM PMQ bietet den Anwendern in den Fachbereichen eine Vielzahl von Vorteilen. Sie können damit folgende Aufgaben lösen:

- Den Ausfall einer überwachten Anlage vorhersagen, damit man sie reparieren und so teure Ausfallzeit vermeiden kann.
- Durch Vorhersagen Wartungspläne für Anlagen optimieren.
- Lernen, welche Anlagenparameter (Messgrößen) den Ausfall eines Bauteils am besten voraussagen helfen.
- Statistische Prozesskontrollanalysen (SPC) auf verschiedene Betriebsparameter einer Anlage anwenden.
- Die Histogramme für die Häufigkeitsverteilung bezüglich mehrerer Betriebsparameter einer Anlage interaktiv untersuchen.
- Die Vorhersagen mehrerer prädiktiver Modelle kombinieren, von denen jedes auf eine Vielzahl von strukturierten, semi-strukturierten und unstrukturierten Daten aus dem Anlagen- und Wartungsbereich zugreift.
- Antworten schneller finden und Korrekturmaßnahmen rascher ergreifen können durch eine verknüpfte und interaktive Ursachenanalyse unter Zuhilfenahme hochwertiger Visualisierungs- und Predictive-Analytics-Techniken, ohne jedoch zwischen verschiedenen Systemen wechseln zu müssen. Dieser Vorgang verringert die Zeit bis zur Wertschöpfung, bis das Problem identifiziert ist, seine



Architektur einer analytischen Gesamtlösung – Integrationsebene liefert Anbindung an Maschinen, Sensoren und andere Datenquellen, Datenhaltungsebene bietet kostengünstige Speicheroption und stellt aufbereitete Daten den analytischen Werkzeugen für Detailauswertung und Visualisierung zur Verfügung. (Bilder: IBM)


Ursache und Gründe lokalisiert und korrigierende Maßnahmen eingeleitet sind.

- Sollten gehäuft Ausfälle oder defekte Produkte auftreten, können Nutzer leichter Frühwarnsignale senden, um dies zu verhindern.
- Leichter Frühwarnsignale senden, sollte eine erhöhte Anzahl von Garantiesprüchen hinsichtlich Ersatzteilen und Reparaturen auftreten. Die Gründe dafür lassen sich analysieren, etwa hinsichtlich Kundendienstqualität, Herstellungsanomalien oder suboptimale Beschaffung.
- Eine individuell angepasste Übersicht über die „Gesundheit“ aller Anlagen mithilfe hochwertiger Modelle errechnen, um die Muster in Sensordaten vorherzusagen, die auf einen bevorstehenden Anlageausfall hinweisen.

Um all diese Vorteile liefern zu können, nutzt IBM PMQ eine Vielzahl von Produkten und Best Practices.

Integriert ist die PMQ-Lösung aus folgenden Gründen:

- IBM PMQ unterstützt alle zuvor illustrierten Reifegrade von deskriptiver über prädiktiver bis hin zu präskriptiver Analyse und kann damit sukzessive **mit den Anforderungen der Nutzer „wachsen“**.
- PMQ fokussiert sich nicht nur auf die analytische Datenhandhabung, sondern unterstützt die **Herausforderungen der Aufnahme und Integration industrieller Daten** durch einen entsprechenden Integrations-Bus.
- Die IBM-Lösung trägt der Notwendigkeit Rechnung, dass Erkenntnis nur dann zu Aktion führt, wenn sie beim Nutzer in der geeigneten Form ankommt und daher eine **Lösung für das unternehmensweite Reporting über verschiedene Endgeräte** mitliefert.
- Die Komponenten von PMQ sind nicht als einzelne Elemente, sondern im wahrsten Sinne des Wortes über ein **erweiterbares Industrie-Datenmodell integriert**,



Die einzelnen Elemente der PMQ-Lösung sind etablierte Werkzeuge, die für die Entwicklung von Modellen und Erkenntnissen jeweils mit grafischen Oberflächen bedient werden können (Design) und deren Ergebnisse über Berichte oder Dashboards für die verschiedenen Kunden aufbereitet werden (Nutzung).

so dass mit der ersten Datenaufnahme sofort die ersten Modelle befüllt und die ersten Standardreports ausgeliefert werden können.

- In kommerzieller Hinsicht nimmt PMQ von traditionellen Preismodellen wie „pay per CPU“ o.ä. Abstand. Vielmehr wird **Asset-basiert gepreist**, so dass die Anzahl der betreuten Assets ausschlaggebend ist. Kosten entstehen damit nur dort, wo auch Wert generiert wird.
- **PMQ liefert sukzessive weitere Funktionen und Modelle mit**, die Aufgaben wie die Anomalieerkennung oder die Trenderkennung in Datensequenzen mit sehr hoher Akkuratheit leisten, ohne dass diese jeweils individuell entwickelt werden müssen. Spezielle Konfigurationen für einzelne Industrien (wie etwa den Energiebereich mit eigenen Datenmodellen) oder spezielle Anwendungsszenarien werden sukzessive ergänzt.
- PMQ ist als **Installationssoftware**, als **Cloud-basierte Variante** und als **Software-as-a-Service** verfügbar.
- **PMQ ist nicht nur eine Softwarelösung**, sondern wird von IBM – zusammen mit seinen internen Experten aus der Entwicklung, dem Consulting, dem transformativen Projektmanagement und Partnern – erfolgreich in Kundenmehrwert verwandelt.

Integration ist für die IBM-Experten nicht nur der entscheidende Anfangspunkt des Weges zur Nutzung des Potenzials von Industrie 4.0 und der Nutzung des in Daten inhärenten Wertes – sie ist auch das vornehmliche Gestaltungsparadigma für IBMs industrielle Kunden-Lösungen.