

WHITE PAPER

Lösungsansätze für vier Herausforderungen bei Predictive Maintenance mit MATLAB und Simulink

Predictive Maintenance (oder vorausschauende Instandhaltung) ist ein äußerst vielversprechender Ansatz zur Verhinderung von Maschinenausfällen und unnötigen Wartungsarbeiten. Außerdem ermöglicht sie Ausrüstern mit entsprechenden Serviceangeboten neue Umsatzströme. Diese klaren Vorteile sind jedoch mit gewissen technischen und geschäftlichen Herausforderungen verbunden.

In mehr als einhundert Gesprächen mit Ingenieuren und Managern wurden vier typische Hindernisse identifiziert, vor denen Unternehmen bei der Implementierung von Predictive Maintenance stehen. Das vorliegende Paper erklärt, wie Sie jedes dieser Hindernisse erfolgreich überwinden.

1. „Wir haben nicht genügend Daten für ein Predictive Maintenance-System.“

Predictive Maintenance beruht in hohem Maße auf Machine Learning. Damit die Algorithmen ein akkurates Modell erstellen können, benötigen sie eine ausreichende Menge an Daten. Bei Predictive Maintenance stammen diese Daten zumeist von Sensoren an den Maschinen. Falls die Sensoren aber noch nicht ausreichend lange eingesetzt werden oder die Methodik bei der Protokollierung der Messungen nur eine begrenzte Datenmenge liefert, müssen Sie sich überlegen, wie Sie an die erforderlichen Daten für Ihre Modelle gelangen.

Welche Datenquellen stehen Ihnen zur Verfügung?


Möglicherweise erfasst Ihre eigene Abteilung nicht genügend Daten, um ein funktionierendes Predictive Maintenance-System entwickeln zu können. Aber wie sieht es mit anderen Abteilungen aus? Erfassen diese ebenfalls Daten? Könnten zum Beispiel die Daten des Teams für Bedienelemente mit denen des Teams für Services kombiniert werden? Die Lösung für Ihr Problem sitzt vielleicht ganz in der Nähe, in einem anderen Büro nur drei Türen entfernt.

Abhängig von der Größe Ihres Unternehmens und von Ihrer Position in der Lieferkette empfiehlt sich gegebenenfalls auch ein Blick auf die Vereinbarungen mit Ihren Zulieferern oder Kunden. Die Kooperation mit Geschäftspartnern zugunsten einer längeren Nutzungsdauer und höheren Effizienz von Ausrüstungskomponenten versetzt alle Beteiligten in eine Win-win-Situation, die den Datenaustausch zwischen verschiedenen Geschäftseinheiten rechtfertigen könnte. Nicht immer wird dies der Fall sein, aber von vornherein verwerfen sollten Sie diese potenzielle Datenquelle nicht!

Wie werden Daten erfasst?

Manche Systeme arbeiten nach dem Prinzip „alles oder nichts“, das heißt, es werden nur wenige oder gar keine Daten erfasst, solange kein Fehler auftritt. Andere Systeme wiederum protokollieren lediglich Ereigniscodes und Zeitstempel – Techniker werden zwar über das eingetretene Ereignis informiert, nicht jedoch über die Sensorwerte zum Zeitpunkt des Eintretens. Wenngleich derartige Daten für Fehlerdiagnosen nützlich sein mögen, reichen sie nicht aus, um Modelle zur Vorhersage zukünftiger Fehler zu erstellen.

Finden Sie heraus, ob Sie die Optionen für die Datenprotokollierung anpassen können, um mehr Daten zu erfassen. Falls nicht genügend Produktionsdaten verfügbar sind, bietet sich vielleicht eine Testumgebung als alternative Datenquelle an. Je nach derzeitiger Datenlast könnten Sie Embedded-Geräte so konfigurieren, dass sie zusätzliche Sensordaten erfassen und übertragen. Eventuell sind zumindest zu Beginn auch externe Datenlogger nötig.



Konfiguration der Datenprotokollierung zwecks Erfassung und Übertragung von Sensordaten

Können Daten mit Simulationstools synthetisiert werden?

Erzeugen Sie Testdaten mithilfe von Simulationstools und kombinieren Sie diese Daten mit verfügbaren Sensordaten, um Algorithmen für Predictive Maintenance zu entwerfen und zu validieren. Zu diesem Zweck müssen Sie Modelle zur Überwachung der involvierten mechanischen, elektrischen oder sonstigen physischen Systeme erstellen. Synthetisieren Sie Stichprobendaten (durch Modellierung erhaltener Ausgaben) und validieren Sie diese mithilfe tatsächlich gemessener Daten, um die korrekte Kalibrierung des Modells sicherzustellen. Anfänglich kann dies auf Komponentenebene geschehen; bei komplexeren Umgebungen ist dies später auf die Systemebene zu erweitern.

Mazda simuliert Daten zur Motorenentwicklung

Mazda stand vor der Aufgabe, Testpläne zu definieren, statistische Modelle zu entwickeln und die optimale Kalibrierung für seinen SKYACTIV-D-Motor zu bestimmen. Das Unternehmen entschied sich dafür, statistische Modelle für den SKYACTIV-G-Motor aufzustellen und HiL-Simulationen (Hardware-in-the-Loop) der Motorsteuerungslogik durchzuführen.

„Bei der herkömmlichen Vorgehensweise wären zur Erfassung von Daten zwecks Kalibrierung eines neuen Motors unzählige Testläufe nötig. Wir haben stattdessen vorhandene Daten genutzt und die Messungen simuliert, wodurch wir sowohl den Arbeitsaufwand zur Datenerfassung als auch die erforderlichen Testzellenressourcen minimieren konnten.“

– Shingo Harada, Mazda
» [Anwenderbericht lesen](#)

Überlegungen

Beginnen Sie bei der Auswahl der nötigen Daten für Ihr Predictive Maintenance-System frühzeitig mit der Datenanalyse, um herauszufinden, welche Datenattribute wichtig sind und welche nicht. Abhängig von Ihren Systemen zur Datenspeicherung könnten Sie auf diese Weise unnötige Kosten durch das Speichern großer Mengen an eigentlich nicht erforderlichen Daten vermeiden. Sobald Sie wissen, welche Attribute unverzichtbar sind, können Sie fundierte Entscheidungen treffen, welche Daten gespeichert und welche Daten verworfen werden sollen. Einer der Vorteile eines Tools wie *MATLAB*® in diesem Zusammenhang ist seine Unabhängigkeit vom gewählten Speichersystem: Auch beim Wechsel von einer lokalen Speicherumgebung in die Cloud können Sie Ihre Analysen mit nur minimalen Anpassungen fortsetzen.

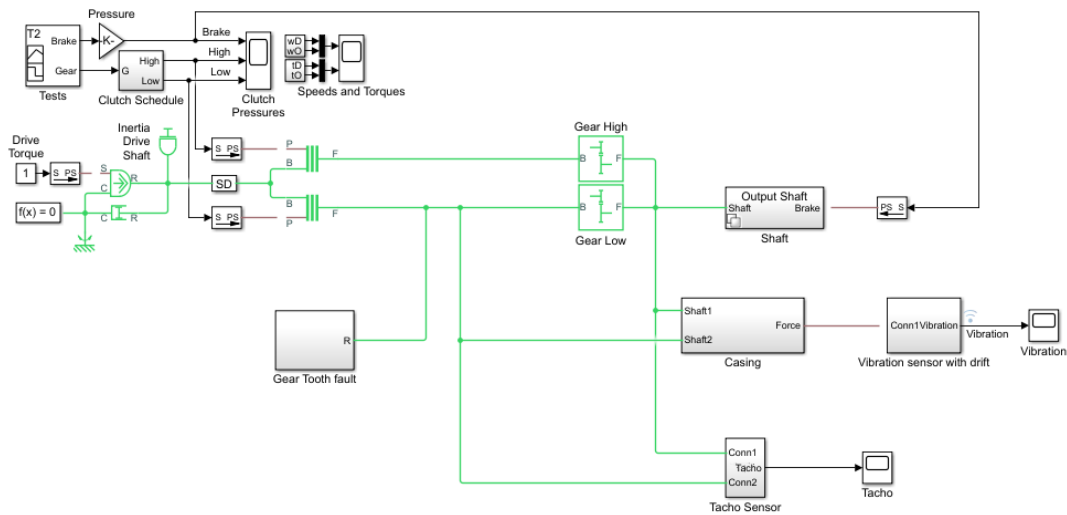
2. „Wir haben keine Ausfalldaten und erhalten daher keine akkuraten Ergebnisse.“

Ausfalldaten spielen eine entscheidende Rolle beim Training von Algorithmen, damit Anzeichen eines drohenden Ausfalls erkannt und rechtzeitige Instandhaltungsmaßnahmen eingeleitet werden können. Unter Umständen sind derartige Ausfalldaten aber nicht vorhanden, wenn Wartungsprozesse so häufig durchgeführt werden, dass es gar nicht zu Ausfällen kommt, oder wenn es bei einem System aufgrund von Sicherheitsanforderungen keinen Ausfall geben darf. Damit Sie und Ihr Team nicht in dieser Sackgasse landen, können Sie Ausfalldaten simulieren und Ihren Algorithmen mithilfe von Betriebsdaten das Erkennen von Anzeichen eines drohenden Ausfalls beibringen.

Erzeugung von Ausfalldaten

Mit den richtigen Tools kann ein Ingenieur, der mit der Funktionsweise und dem Zusammenspiel physischer Komponenten bestens vertraut ist, problemlos Ausfalldaten erzeugen. In einem Simulationsprogramm wie *Simulink*® erstellt der Techniker ein Modell der physischen Maschine, wie unter Punkt 1 beschrieben. Anhand einer Fehlerauswirkungsanalyse (FMEA) wird dann festgelegt, welche Fehler und Ausfälle zu simulieren sind. Ein entsprechend qualifizierter Ingenieur führt diese Fehler und das resultierende Systemverhalten in einem Modell zusammen, das zahlreiche Ausfallszenarien beispielsweise durch Variation von Temperaturen, Durchflussraten und Vibrationen oder durch spontan auftretende Fehler simuliert. Die bei diesen simulierten Szenarien gemessenen Ausfalldaten werden gekennzeichnet und für weitere Analysen gespeichert.

Produkte wie die *Predictive Maintenance Toolbox*™ vereinfachen Aufgaben wie die *Erzeugung von Ausfalldaten* und bieten Daten-Ensembles zur Verwaltung und Organisation multipler Datensätze.



Nutzung von Simulink zur Erzeugung von Ausfalldaten

Airbus modelliert multiples Komponentenversagen für den A380

Airbus hatte es sich zum Ziel gesetzt, die Sicherheit bei Ausfällen im komplexen Treibstoffmanagementsystem des A380 zu erhöhen. Zur Verbesserung des Modells simulierte das Team verschiedene Ausfälle. Nach erfolgreichen Flugtests wurden die Abweichungen zwischen den gemessenen Daten und den vorhergesagten Ergebnissen ausgewertet, um die Modelle noch besser anzupassen.

„Das modellbasierte Design hat uns den funktionalen Entwurf des Systems deutlich erleichtert. Zudem konnten wir die Anforderungvalidierung früher abschließen als bisher und multiples Komponentenversagen simulieren, sodass wir besser verstehen, wie sich verschiedene Fehlerarten auswirken. Wir sind zuversichtlich, dass die Steuerungslogik bei Ausfällen ordnungsgemäß reagiert.“


– Chris Slack, Airbus

» [Anwenderbericht lesen](#)

Was für Daten sind verfügbar?

Wenn Ausfalldaten nicht verfügbar sind, können möglicherweise Betriebsdaten Trends bezüglich der nachlassenden Leistungsfähigkeit von Maschinen aufzeigen.

Die Fülle an Rohdaten zu einer Komponente, einem System oder einer Maschine mit Dutzenden oder gar Hunderten Sensoren mag auf den ersten Blick beängstigend erscheinen. Statistische Verfahren wie die Hauptkomponentenanalyse (PCA) können die Dimensionalität dieser Datenmengen jedoch verringern und wertvolle Erkenntnisse zur Arbeitsweise von Maschinen im Zeitverlauf liefern. Die PCA ist eine von vielen Methoden beim unüberwachten Lernen. Dabei handelt es sich um eine Form des Machine Learning, bei der in unbeschrifteten Daten nach Mustern und Trends gesucht wird. Je nachdem, welche Sensoren zur Verfügung stehen, müssen bei bestimmten Ausfallarten gegebenenfalls mehrere Sensoren gleichzeitig ausgewertet werden, um unerwünschtes Maschinenverhalten zu erkennen. Beim unüberwachten Lernen werden Sensorrohdaten in eine Darstellung niedrigerer Dimensionalität überführt, die sich deutlich einfacher visualisieren und analysieren lässt.



Visualisierung von Trends im Geräteverhalten vor einem Ausfall mithilfe der Hauptkomponentenanalyse (PCA)

Überlegungen

Verwenden Sie nur so viele Variablen, wie Sie zum Entwurf eines akkuraten Modells tatsächlich benötigen. Es mag verlockend sein, jede gemessene Komponente in das Modell aufzunehmen, um ja keine Daten zu verlieren. Aber das führt nur zu einem unnötig komplexen Modell. Methoden wie die Hauptkomponentenanalyse vermeiden dies und stellen eine quantitativ rigorose Vorgehensweise zur Modellvereinfachung dar.

3. „Wir verstehen Ausfallursachen, können sie aber nicht vorhersagen.“


Das Verständnis der Ursachen eines Ausfalls ist für Ihr Geschäft zweifelsohne wichtig. Die reine Analyse von Fehlerursachen ist jedoch nicht dasselbe wie das Wissen, wie sich künftige Fehler vorhersagen lassen. Die Fehlerursachenanalyse ist zusammen mit vorausschauenden Algorithmen ein wesentlicher Bestandteil eines funktionierenden Predictive Maintenance-Programms. Falls der Entwurf von Algorithmen für Sie eine noch neue Aufgabe darstellt und unlösbar scheint, können Sie mit folgenden Schritten Ihre Lernkurve verkürzen.

Definition klarer Ziele

Woher wissen Sie, ob ein Predictive Maintenance-Algorithmus bessere Ergebnisse erzielt als Ihre bisherige Vorgehensweise? Um dies herauszufinden, sollten Sie Ihre Ziele von vornherein klar definieren (z. B. schnellere Erkennung von Ausfällen, längere Zyklen, kürzere Ausfallzeiten). Überlegen Sie anschließend, wie sich der vorausschauende Algorithmus auf diese Ziele auswirkt. Um Designiterationen zu beschleunigen, entwerfen Sie ein Framework zum Testen und Evaluieren der Performance von Algorithmen im Hinblick auf Ihre gesetzten Ziele. So stellt sich nicht länger die Frage, ob ein Algorithmus den bisherigen Zustand verbessert oder nicht. Vielmehr wird klar, inwieweit der Algorithmus Sie Ihren Zielen näher bringt.

Kleine Schritte zu Beginn

Wenn Sie und Ihr Team die Ursachen von Ausfällen bereits kennen, sind die erforderlichen Kenntnisse zur fraglichen Domäne klar vorhanden. Wählen Sie darum zu Übungszwecken ein System, mit dem Sie bestens vertraut sind. Stellen Sie sicher, dass Sie genau verstehen, welche Funktionen und Faktoren die Performance des Systems beeinflussen, und entwickeln Sie basierend darauf Ihren Predictive Maintenance-Algorithmus. Ein einfacher Ausgangspunkt wäre die Überprüfung, ob sich eine Schwellenwertkontrolle für ein Merkmal als signifikanter Indikator für fällige Instandhaltungsmaßnahmen eignet (dies wird üblicherweise mit Regelkarten realisiert). Die Fachkenntnisse Ihres Teams erleichtern die Auswahl der Hauptkomponenten und Schwellenwerte (beispielsweise ein Sicherheitslimit, das nie überschritten werden darf). Darüber hinaus könnten Sie einfache Modelle wie die lineare oder logistische Regression ausprobieren, da diese sich schnell an die Daten anpassen und sehr leicht auswerten lassen. Sobald Sie und Ihr Team den Entwurf von Algorithmen für einfache Problemstellungen beherrschen, können Sie sich an komplexere Systeme wagen.



Modellierung von drei Fehlerarten: Zylinderlecks, blockierter Zufluss und erhöhte Lagerreibung

Wachsendes Selbstvertrauen

Sobald Ihre Predictive Maintenance-Algorithmen vielversprechende Ergebnisse erzielen, nutzen Sie aktuelle und frühere Daten, um Ihre Modelle vor dem Einsatz in der Produktion ausführlich zu testen und zu validieren. Machen Sie sich die Fachkenntnisse Ihres Teams zunutze und justieren Sie Ihre Modelle so, dass unterschiedliche Ergebnisse auf der Grundlage ihrer jeweiligen Kosten/Schweregrade vorhergesagt werden können. Ergänzen Sie für die Validierung Ihrer Modelle synthetisierte Ausfalldaten, mit denen bekannte frühere Bedingungen nachgebildet werden, um Ihr System weiter zu testen. Mit diesem Validierungsschritt stärken Sie Ihr Vertrauen in den entwickelten Algorithmus, da erkennbar wird, ob das Modell akkurat arbeitet oder an welchen Stellen Abweichungen zwischen Simulation und Realität weitere Justierungen erfordern.

Überlegungen

Wie bei jeder neuen Aufgabe sollten Sie auch hier Geduld zeigen und sich Schritt für Schritt an die Lösung herantasten, damit Sie die Komplexität Ihres Vorhabens nicht schon nach kurzer Zeit entmutigt. Definieren Sie klare Ziele, steigern Sie sich nach und nach, validieren Sie Ihre Lösung mithilfe vorhandener Daten und wiederholen Sie den Vorgang, bis Sie mit den Ergebnissen wirklich zufrieden sind. Beschränken Sie sich zunächst auf einzelne Komponenten, bis Sie die Vorgehensweise so gut beherrschen, dass Ihnen auch komplexe Systeme keine Schwierigkeiten mehr bereiten.


4. „Wir wissen nicht, wie wir Predictive Maintenance implementieren sollten.“

Jede erforderliche Investition in neue Technologien muss gerechtfertigt sein. Idealerweise sollte so wenig Zeit wie möglich vergehen, bis sich eine Investition rentiert. Doch die Quantifizierung der Zeitdauer bis zur Realisierung der Investitionsrendite wird erschwert, wenn ungewiss ist, wie schnell Sie und Ihr Team sich die neuen Fähigkeiten aneignen können. Falls maschinelles Lernen erst vor Kurzem in Ihrem Unternehmen eingeführt wurde, ist nachvollziehbar, dass eine fortgeschrittene Anwendung dieses Verfahrens zunächst noch als Risiko eingestuft wird. Durch konkrete Maßnahmen können Sie dieses Risiko jedoch minimieren und schnellstmöglich ein funktionales Modell für Predictive Maintenance implementieren.

Mit welchen Tools sind Ihre Techniker bereits vertraut?

Statt vorschnell neue Technologien und Methoden einzuführen, schauen Sie sich genau an, welche Funktionen Ihre vorhandene Software bereits bietet, und konzentrieren Sie sich auf die neue Methodik. Manche der von Ihren Technikern genutzten Tools, wie z. B. MATLAB, verfügen über spezifische Optionen für Predictive Maintenance, sodass Ihre Fachkräfte weiterhin in der ihnen bereits bekannten Umgebung arbeiten können. Diese Tools umfassen zudem Referenzbeispiele und -algorithmen, um Einsteiger zügig in Predictive Maintenance einzuführen, sowie entsprechende technische Unterstützung, Schulungsangebote und Beratungsteams. Dank dieser zusätzlichen Anleitung sind die Grundvoraussetzungen in Ihrem Unternehmen schnell geschaffen und Ihr Team kann darauf vertrauen, dass Probleme auf effiziente Weise in Angriff genommen werden.

Welchem Arbeitsablauf folgt Predictive Maintenance?



Grundlegender Arbeitsablauf bei Predictive Maintenance

Der erste Schritt beim Entwurf eines funktionalen Modells besteht in der Aufstellung des Arbeitsablaufes und in der Identifizierung möglicher Hindernisse und Engpässe. Die Entwicklung und Implementierung von Predictive Maintenance-Algorithmen erfolgt in fünf Phasen:

1. Zugriff auf Sensordaten

Daten können aus unterschiedlichen Quellen erfasst werden, zum Beispiel aus Datenbanken, Kalkulationstabellen oder Webarchiven. Achten Sie stets auf das korrekte Datenformat, einschließlich Datums- und Zeitstempel. Größere Datensätze passen eventuell nicht in den Arbeitsspeicher und müssen außerhalb oder in einem Cluster verarbeitet werden. Häufig geht es darum, wie man die Daten für die Analyse organisiert. Falls Ihnen nicht genügend Daten zur Verfügung stehen, können Sie anhand eines Modells der physischen Maschine zusätzliche Daten generieren und die normale Nutzung, variierende Parameterwerte, unterschiedliche Systemdynamiken oder Signalfehler simulieren.

2. Datenvorverarbeitung

Daten aus der realen Welt sind selten perfekt, sondern umfassen auch Ausreißer und Störungen durch Rauschen, die es zu beseitigen gilt, um einen realistischen Eindruck des normalen Verhaltens zu erlangen. Falls Daten verschiedenen Quellen entstammen, müssen diese zudem kombiniert werden. Überlegen Sie bei der Bereinigung von Anomalien, ob Sie sie durch geschätzte Werte ersetzen oder mit einem kleineren Datensatz arbeiten möchten. Potenzielle Schwierigkeiten ergeben sich bei der Justierung von Filtern für Rauschen oder Ausreißer sowie bei der Bewertung der Auswirkungen verschiedener Filter auf die generelle Performance des Algorithmus.

3. Merkmalsextraktion

Üblicherweise werden Sensordaten nicht direkt in Modelle zum Machine Learning eingespeist. Stattdessen werden aus diesen Daten Merkmale extrahiert. Diese Merkmale beschreiben abstraktere Informationen in den Sensordaten, zum Beispiel gleitende Mittelwerte oder Frequenzinhalte. Nur wenige Ingenieure beherrschen Verfahren der Statistik, der Signalverarbeitung und der Systemmodellierung im Schlaf, weswegen die Verwendung vertrauter Tools zur Merkmalsextraktion diesen Schritt erleichtert. Eine iterative Vorgehensweise, bei der Merkmale hinzugefügt, neue Modelle trainiert und ihre Ergebnisse verglichen werden, ist unter Umständen gut geeignet, um die Auswirkungen unterschiedlicher Merkmale auf die Ergebnisse zu prüfen.

Baker Hughes extrahiert Merkmale zum Training von Modellen für Erdöl- und Erdgasfördermaschinen

Das Team von Baker Hughes nutzte MATLAB zur Analyse seiner Daten von Erdöl- und Erdgasfördermaschinen, um herauszufinden, anhand welcher Signale in den Daten sich Abnutzungserscheinungen in den Maschinen am besten erkennen lassen. Die Vorgehensweise umfasste Fourier-Transformationen und eine Spektralanalyse sowie das Herausfiltern stärkerer Bewegungen von Trucks, Pumpen und Flüssigkeiten, um auf diese Weise schwächere Vibrationen der Ventile und Ventilsitze erfassen zu können.


„Dank MATLAB konnten wir zuvor unlesbare Daten in ein lesbares Format überführen, zudem die Filterung, Spektralanalyse und Transformationsschritte für mehrere Trucks und Regionen automatisieren und schlussendlich maschinelle Lernverfahren in Echtzeit anwenden, um den optimalen Zeitpunkt zur Durchführung von Instandhaltungsmaßnahmen zu bestimmen.“

– Gulshan Singh, Baker Hughes

» [Anwenderbericht lesen](#)

4. Training des Modells

In dieser Phase werden Daten als „korrekt“, „fehlerhaft“ klassifiziert, Schwellenwerte für ordnungsgemäße/ gefährdete/kritische Zustände festgelegt und Formeln zur Schätzung des Remaining Useful Life (RUL, wirtschaftliche Restlebensdauer) von Komponenten aufgestellt. Sie müssen hierzu eine umfangreiche Liste der vorherzusagenden Ausfallszenarien erstellen, Klassifikationsmethoden wählen und Modelle simulieren. Apps bieten grafische Schnittstellen zur Anwendung von Verfahren zum Machine Learning, die Ihnen die ersten Schritte und den Vergleich der Trainingsergebnisse vieler verschiedener Modellarten erleichtern.



Training vorausschauender Modelle zur Schätzung des Remaining Useful Life von Komponenten und Angabe von Konfidenzintervallen für die Ergebnisse

5. Bereitstellung des Modells

In der letzten Phase gilt es, den Code zu generieren und die Modelle als Anwendungen auf Ihrer Hardware bereitzustellen. Modelle können durch Konvertierung in eine niedrigere Programmiersprache wie C für Embedded Geräte bereitgestellt oder in andere Anwendungen innerhalb einer IT-Umgebung integriert werden. Ein Hindernis ist in diesem Fall häufig die mangelnde Vertrautheit mit der Codegenerierung und IT-Integration. Es gibt jedoch Tools wie *MATLAB Compiler™* und *MATLAB Production Server™*, die Ihre Modelle automatisch für Produktionsumgebungen kompilieren. Die Verfügbarkeit von Consulting kann sich bei der Integration von Anwendungen in Ihre IT-Systeme als besonderer Vorteil erweisen.

Mondi entwickelt ein Predictive Maintenance-System

Das Kunststoffproduktionswerk von Mondi Gronau ist rund um die Uhr in Betrieb. Mit der Unterstützung von MathWorks Consulting entwickelte das Team eine Anwendung zur Überwachung des Systemzustands und für Predictive Maintenance, das das Anlagenpersonal in die Lage versetzt, korrektive Maßnahmen rechtzeitig zu ergreifen und schwerwiegende Probleme zu verhindern. Das Projekt wurde in nur sechs Monaten abgeschlossen und spart dem Unternehmen künftig geschätzt 200.000 Euro pro Jahr.

„Die Supportleistungen von MathWorks Consulting gehören zu den Besten der Branche. Die Berater arbeiten schnell und sind äußerst kompetent. Unsere Investition hat sich dank der erzielten Kosteneinsparungen bereits rentiert. Jetzt haben wir zusätzliche Finanzmittel und Zeit für weitere Projekte mit Machine Learning, die uns sicher ähnliche Vorteile bieten werden.“

– Dr. Michael Kohlert, Mondi

» [Anwenderbericht lesen](#)

Überlegungen

Manchen Unternehmen genügen tägliche Berichte zur Leistung ihrer Maschinen, während andere Unternehmen die Überwachung in Echtzeit erfordern. Überlegen Sie sich, in welchem Umfang Sie Ihre Abläufe überwachen müssen. Bedenken Sie dabei auch die erfassten Datentypen – handelt es sich um Signaldaten, Bilddaten oder Textdaten und inwiefern eignen sie sich zur Vorhersage künftiger Ausfälle? Je größer die Datenmenge, desto mehr Rechenleistung wird beansprucht. Zu guter Letzt sollten Sie entscheiden, wie die Ergebnisse visuell aufzubereiten sind, in welchem Umfang die Anlässe für die Ausgabe von Warnmeldungen dargestellt werden sollten und wer über drohende Ausfälle zu benachrichtigen ist.

Schlussfolgerung

Predictive Maintenance-Maßnahmen lassen sich mit den richtigen Tools, mit der nötigen Anleitung und mit gebührender Motivation problemlos realisieren. Sie müssen lediglich herausfinden, welche Merkmale, Modelle und Methoden sich am besten für Ihr Unternehmen eignen, und Ihre Lösungen sodann testen und validieren, bis Sie mit den Ergebnissen zufrieden sind. Bei Bedarf stehen wir Ihnen jederzeit unterstützend zur Seite!

Mehr Infos

- [Predictive Maintenance mit MATLAB: Vermeiden teurer Geräteausfälle mithilfe von Sensordatenanalysen](#) – E-Book
- [Maschinelles Lernen mit MATLAB](#) – E-Book
- [MathWorks Consulting für Predictive Maintenance – Serviceübersicht](#)