

Vorausschauende Instandhaltung mit datengetriebener Zustandsüberwachung – Teil 2

von **Hartmut Steck-Winter, Carsten Stöling, Günther Unger**

Die vorausschauende Instandhaltung ergänzt die traditionellen präventiven Instandhaltungsstrategien und berücksichtigt dabei auch mathematische Methoden zur automatisierten Prognose von Restlebensdauern und Risikoprofilen. Sie soll die diagnostische Instandhaltungsplanung mit einer leistungsfähigen Prognostik erweitern und so eine bessere und kostenreduzierte Instandhaltung unterstützen. Weil Big Data, Analytics und digitale Zwillinge dabei wichtige Rollen spielen, ist sie eine Instandhaltungsstrategie, die in der Industrie 4.0 ihr ganzes Potenzial entfaltet. Im vorliegenden zweiten Teil des Beitrags wird ausgeführt, wie die datengetriebene Zustandsüberwachung mit der vorausschauenden Instandhaltung zusammenwirkt. Teil 1 ist in gwi – gaswärme international 5/2017 erschienen.

Predictive maintenance with data-driven condition monitoring – part 2

Predictive maintenance complements the traditional preventative maintenance strategies and also takes mathematical methods for the automated prognosis of residual life and risk profiles into account. It is intended to extend the diagnostic maintenance planning with a powerful forecasting system and thus support better and cost-reduced maintenance. As big data, analytics and digital twins play important roles, it is a maintenance strategy that unfolds its full potential in an Industrie 4.0 environment. In the second part of this paper at hand, we will discuss how the data-driven condition monitoring works in conjunction with predictive maintenance. Part 1 was published in gwi – gaswärme international 5/2017.

Die vorausschauende Instandhaltung baut auf der datengetriebenen Zustandserfassung auf, die Verschleißsymptome von ausgewählten werthaltigen Bauteilen erkennt, um die voraussichtliche Entwicklung des künftigen Bauteilzustandes vorherzusagen.

Insbesondere sollen in diesem Beitrag folgende Fragen beantwortet werden:

- Wie wirken die datengetriebene Zustandsüberwachung, Big Data und eine vorausschauende Instandhaltung zusammen?
- Was genau ist mit vorausschauender Instandhaltung gemeint? Welche Vor- oder Nachteile hat sie gegenüber anderen präventiven Instandhaltungsstrategien?
- Was ist bei einer Lebensdauerprognose zu berücksichtigen?

- Wie greifen die datengetriebene Zustandsüberwachung, Ersatzteilbedarfsplanung und Wartungsplanung in einem integrierenden digitalen Service-Geschäftsmodell ineinander?

Rückblick auf Teil 1

Doch zunächst ein kurzer Rückblick auf die datengetriebene Zustandsüberwachung, die im ersten Teil beschrieben wurde. Es ging dabei hauptsächlich um die Nutzung von Daten, die von der Automatisierungstechnik bereits verarbeitet werden. Diese Daten können auch für die Zustandsüberwachung ausgewertet werden, beispielsweise weil sich Zeitdauern oder der Strom vieler elektromechanischer Bauteile verschleißabhängig direkt oder indirekt verändern oder aber charakteristische Ereignismuster auftreten.

Ergänzend kommen Prozessdatenvalidierung und Control Performance Monitoring zum Einsatz, die ganz wesentlich dazu beitragen, Zustandsinformationen aus dem Ofeninnern zugänglich zu machen.

Im Fokus standen Bauteile in und an Thermoprozessanlagen (**Bild 1**), für die es keine Condition Monitoring Sensoren gibt und deren Abnutzung oder Ausfall lange Stillstandszeiten, Qualitätseinbußen oder Gefährdungen nach sich ziehen und/oder hohe Kosten verursachen. Also



Bild 1: Bauteile einer Thermoprozessanlage

alle Bauteile, die einen hohen Einfluss auf die Sicherheit, Verfügbarkeit, Wirtschaftlichkeit und Produktionsqualität der Anlage haben.

Solche Bauteile in und an Thermoprozessanlagen sind z. B. Ausmauerungen, Gleitsteine, Muffeln, Kettenführungs-schienen, Strahlrohre, Brenner, Gasumwälzer, Kontakteinrichtungen, Transportsysteme, Türen, Siphons, Wärmetauscher etc.

Big Data: Das Versprechen der Allwissenheit

Bei der Datenerfassung und -speicherung der Zustandsdaten fallen riesige Datenmengen an. Noch vor wenigen Jahren wurden solche Datenansammlungen recht zutreffend Datenfriedhöfe genannt, weil es nicht gelungen ist, aus diesen Daten einen wahren Nutzen zu ziehen. Heute ist die Lösung scheinbar greifbar nahe: „Big Data – Das neue Versprechen der Allwissenheit“ (so ein populärer Buchtitel) bringt die Erwartungen auf den Punkt. Die Herausforderung liegt „nur noch“ in der Antwort auf die Frage, wie große Datenmengen mit unterschiedlichster Strukturierungsform (Sensordaten, Dokumente, Texte, Fotos, Videos) und Entstehungsart (synchron, asynchron) in kurzer Zeit (d. h. möglichst in Echtzeit) gespeichert, analysiert und für den Benutzer leicht verständlich zu Smart Data aufbereitet werden können.

Vor der Analyse steht aber das Sammeln von Daten, wie dies im ersten Teil des Beitrags ausgeführt wurde, und die braucht Zeit, weil Abnutzung und Verschleiß sehr langsa-

me Prozesse sind. Je umfangreicher die Datenbasis und je besser deren Qualität, desto präziser die Analysen. Die Frage „Sammeln Sie noch oder analysieren Sie schon?“ wird also zum Prüfstein für den eigenen Reifeprozess in der vorausschauenden Instandhaltung.

Exkurs: Cloud. Oder nicht Cloud?

Damit wirft sich auch die Frage auf, ob die Daten zentral, dezentral oder verteilt gespeichert und verarbeitet werden sollen. Welche Kriterien hierbei zu beachten sind, soll nun im Weiteren umrissen werden:

Cloud Computing

Beim Cloud Computing werden die lokalen Informations- und Kommunikationstechniken (IKT) sowie die Steuerungssysteme über das Internet mit einer Cloud verbunden.

Cloud Computing funktioniert wie Strom aus der Steckdose¹. Der Kunde kauft die benötigte Rechenleistung und Services und zahlt nach Verbrauch. Dabei wird unterschieden zwischen der reinen Bereitstellung der Computerhardware (Infrastructure as a Service – IaaS bzw. Platform as a Service – PaaS), auf denen Nutzer eigene Software ausführen können, sowie der bedarfsweisen Bereitstellung von speziellen Anwendungsprogrammen (Software as a Service – SaaS). Dazu gehören einige der derzeit wachstumsstärksten Produkte, die sogenannten „Analytics-as-a-Service“. Gemeint sind damit „mächtige Werkzeuge“ für das Data Mining, Analysen und Prognosen. Sie machen die Cloud zu einem agilen Superrechner, oft zu deutlich geringeren Kosten als die herkömmliche EDV. Daten und Programme werden in der Cloud zentral verwaltet und gepflegt. Alle berechtigten Anwender haben stets Zugriff auf aktuelle Informationen, auch wenn sie mobil sind. Zudem ermöglicht eine Cloud eine einfache Anbindung externer Partner, die so die für sie freigegebenen Informationen einsehen können. Durch das Zusammenführen von Daten und Informationen einer Vielzahl von Anlagen und Prozessen, ggf. auch über verschiedene Werke und Betreiber hinweg, kann eine signifikant breitere bzw. bessere Wissensbasis geschaffen werden. Zusammengefasst sind die Vorteile des Cloud Computing also bestechend.

Ohne eine ständige Verbindung mit dem Internet wird Cloud Computing aber nicht funktionieren. Damit werfen sich dann die altbekannten Sicherheitsfragen wieder auf², die in nicht wenigen Unternehmen (noch) eine unüberwindbare Hürde sind [1].

¹ Die Bereitstellung von Cloud Computing ist (noch) eine Domäne der großen Softwarehäuser oder Anbieter von Automatisierungstechnik, z. B. Blue Yonder, IBM, SAP oder Siemens, die Hardware und Programme auf Clouds vermieten.

² Die Diskussion um die Sicherheit von Cloudlösungen hält schon lange an. Bewertet man die Sicherheitskonzepte von professionellen Cloudbetreibern, werden sich diese in aller Regel um ein x-faches besser herausstellen als eigene Lösungen. Nicht selten wird man zum Schluss kommen, dass die Daten in einer professionell betriebenen Cloud sicherer sind, als im eigenen Server.

Lokale und hybride IKT-Systeme

Sind dezentralisierte lokale IT-Systeme dann nicht doch die bessere Lösung? In der Automatisierungstechnik sind dezentralisierte Automatisierungsgeräte Stand der Technik. Anlagennahe Funktionen so dezentral wie möglich zu verarbeiten, ist ein Prinzip der Automatisierungstechnik. Damit hat man das (noch) heikle Thema Datensicherheit besser im Griff, ohne an völlig isolierte Systeme zu denken, die dem Grundgedanken der Industrie 4.0 völlig zuwiderlaufen.

Für alle anlagennahen Funktionen ist eine lokale Speicherung und Datenverarbeitung, sozusagen little Big Data, in einem Prozessleitsystem (PLS) – z. B. Aichelin Focos 4.0 – eine gute Wahl. Schon mit wenigen, meist aus SPC-Programmen gut bekannten Methoden lassen sich Trends visualisieren und zusammenhängende Daten aggregieren [2]. So kann dann auch besser sichergestellt werden, dass die notwendigen minimalen Reaktionszeiten erreicht werden können.

Lokale PLS finden dort ihre Einsatzgrenzen, wo aus vielen unstrukturierten Daten bisher unbekannte Ereignismuster und Zusammenhänge mit typischerweise Cloud-basierenden Mustererkennungs- oder Analytics-as-a-Service-Programmen aufgedeckt werden sollen und insbesondere auch dann, wenn Daten über mehrere Prozesse und Anlagen hinweg ausgewertet werden müssen.

Nach Ansicht der Autoren ist die Antwort auf die Frage „Cloud oder PLS“ nicht ein Entweder-Oder, sondern ein Sowohl-als-Auch, je nach Datentypus und Anforderung. Beispielsweise sind Data Mining oder eine Text- und Bildanalyse in einer Cloud sicher besser aufgehoben, es macht aber wenig Sinn, vergleichsweise einfache Trendanalysen in die Cloud zu verlagern.

Hybride IKT-Systeme, bei denen die ersten Auswertungen lokal (im PLS) durchgeführt werden und die aggregierten Daten und Auswertungen dann an eine zentrale Stelle (Cloud) für die weitere Verarbeitung übermittelt werden, sind mit hoher Wahrscheinlichkeit die Lösung der Zukunft [WGP]. Im Übrigen kann es manchmal auch sinnvoll sein, mit einem Cloud-basierenden Analytics-as-a-Service-Programm im ersten Schritt Zusammenhänge aufzudecken und deren kontinuierliche Überwachung dann im zweiten Schritt auf ein lokales PLS zu verlagern.

Vorausschauende Instandhaltung

Damit kommen wir zu den zentralen Fragen, was mit vorausschauender Instandhaltung genau gemeint ist und warum sie die Instandhaltungsstrategie der Industrie 4.0 [3–4] genannt wird.

Die vorausschauende Instandhaltung (Englisch „Predictive Maintenance“, mit PM abgekürzt) ergänzt sowohl die periodische als auch die zustandsabhängige Instandhaltung und berücksichtigt dabei auch Ereignismuster, Einflussfaktoren und mathematische Methoden zur auto-

matisierten Erstellung von Risikoprofilen, z. B. der Voraussage der Restlebensdauer (RUL³) von wichtigen Bauteilen. Weil Big Data und Analytics dabei wichtige Rollen spielen, wird sie auch die Instandhaltungsstrategie der Industrie 4.0 genannt.

Eine vorausschauende Instandhaltung kann, wie in **Bild 2** dargestellt, als Prozess zur Beantwortung von vier

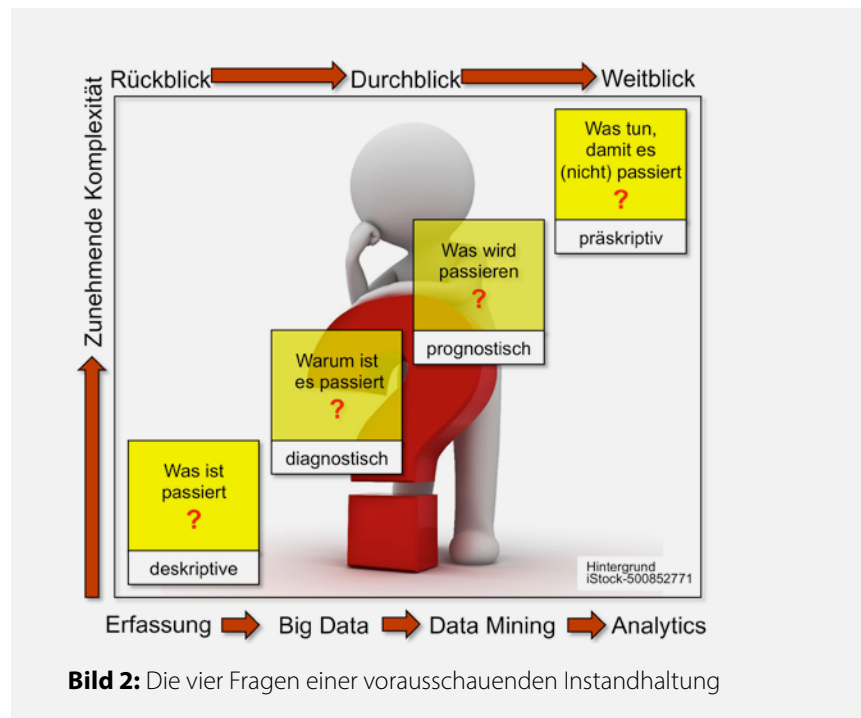


Bild 2: Die vier Fragen einer vorausschauenden Instandhaltung

Fragen betrachtet werden. Mit dem Data Mining werden die Datensätze vergangener Ereignisse untersucht. Daraus lassen sich sowohl Rückschlüsse ziehen (Was ist passiert?) als auch die Frage „Warum ist etwas passiert?“ beantworten. Predictive Analytics geht dann noch darüber hinaus und beantwortet die Frage „Was wird (mit welcher Wahrscheinlichkeit) passieren?“ Mit Simulationsunterstützung werden daraus Handlungsempfehlungen „Was sollte getan werden, damit es (nicht) passiert?“ abgeleitet.

Diese Prozesse werden nachfolgend etwas genauer unter die Lupe genommen.

Data Mining: Muster in unbekanntem Zusammenhängen finden

Data Mining beantwortet die beiden Fragen „Was ist passiert und warum?“ Data Mining steht für das intelligente Suchen, Finden und Erkennen von relevanten Ereignissen und Mustern in großen Datenmengen. Dies ist zwar schon lange ein Ziel der elektronischen Informationsverarbeitung, durch Data Mining ist eine Umsetzung allerdings deutlich realistischer geworden [5].

³ RUL = Remaining Useful Life

Beim Stichwort Data Mining denken wir meist an Zeitungsberichte über die Erfolge bei der Verbrechensbekämpfung mit Predictive Policing, wenn die Wahrscheinlichkeit von Einbrüchen in bestimmten Regionen analysiert wurde und die Polizei weitere Straftaten präventiv verhinderte. Wir fragen uns dann, wie das wohl alles so funktioniert und hoffen, dass sich das Prinzip auch auf andere Bereiche und technische Fragestellungen übertragen lässt⁴. Das ist ja gar nicht so weit hergeholt. Informationen zur Beurteilung des Anlagenzustandes und der einzelnen Bauteile sind in der Gesamtheit der Messwerte und Ereignisdaten der Anlagen auch irgendwie enthalten, jedoch nur selten direkt greifbar.

Zusätzlich zur seit langem bekannten Trendanalyse, die den zeitlichen Verlauf eines bekannten Merkmals beobachtet (und für die man auch keine Data Mining Programme benötigt), geht es beim Data Mining darum, in den vorhandenen Datenmengen mehrdimensionale Muster (Cluster und deren Korrelationen) zu finden. Im Wesentlichen sollen die Ereignisse identifiziert werden, die in der Vergangenheit zu einem Ausfall der Bauteile beigetragen haben, um dann in quasi Echtzeit die Situationen zu identifizieren, die diesen ähnlich sind. Die gesuchten Informationen sind allerdings häufig mit irrelevanten Daten vermischt. Ein notwendiger Zwischenschritt ist also, die Nutzinformation vom Rest der Daten zu separieren, um eine verlässliche Datenbasis zu generieren. Dazu wird die Datenmenge erst einmal reduziert und auf deren signifikante Merkmale reduziert. Die so aufbereitete Datenanalyse muss dann zwingend mit Expertenwissen kombiniert werden. Ohne Expertenwissen sind Daten quasi Muster ohne Wert.

Beim Data Mining werden grundsätzlich zwei Vorgehensweisen unterschieden. Die klassische, am häufigsten angewandte, Methode ist die, dass zuerst durch einen Experten eine Hypothese aufgestellt wird, die dann entweder bestätigt oder verworfen wird⁵. Diese Methode orientiert sich an traditionellen wissenschaftlichen Methoden. Der andere Ansatz ist, dass aus den Daten selbstlernend Hypothesen generiert werden, die interessant sein könnten und die erst dann durch Experten auf ihre Plausibilität beurteilt werden [5]. Propheten der digitalen Welt propagieren daher bereits ein Zeitalter, in der die Ursachen und Wirkungen nicht mehr verstanden werden müssen, sondern durch blitzschnelles Durchforsten von riesigen Datenmengen Muster und Korrelationen erkannt werden, die Antworten auf Fragen geben, die nicht mehr gestellt werden müssen. Nicht wenige sind nämlich dazu geneigt anzunehmen, dass eine genügend intelligente Software

schon alles richten wird. Sie scheinen zumindest in Teilbereichen auch recht zu bekommen.

Analytics: Lebensdauerprognosen

Kernaufgabe der vorausschauenden Instandhaltung ist es, aus den verdichteten Daten Informationen über den Bauteilezustand und die Restlebensdauer zu gewinnen und die Frage „Was wird wann passieren?“ zu beantworten. Lebensdauerprognosen sind die Grundlage jeder präventiven Instandhaltungsplanung als auch der Ersatzteilbedarfsplanung [6].

Wenn der Verschleiß eines Bauteils stetig erfolgt, kann auch der wahrscheinliche Verlauf mit einem Mittelwert und einer Streubreite als verbleibende Lebensdauer vorhergesagt werden. Dazu bedarf es eines mathematischen Modells. Liegt der tatsächliche Verschleißfortschritt bei einer Zustandsinspektion innerhalb der Streubreite, so war die Prognose zutreffend.

Jede Lebensdauerprognose ist stets mit einer Eintrittswahrscheinlichkeit verknüpft, z. B. Restlebensdauer 4 Jahre bei einer Ausfallwahrscheinlichkeit von 25 % oder 2,5 Jahre bei einer Ausfallwahrscheinlichkeit von 10 %. Bei der Festlegung eines präventiven Instandhaltungstermins eines wichtigen Bauteils wird sich die Instandhaltung i. d. R. an der Ausfallwahrscheinlichkeit orientieren. Je größer die Ausfallfolgen, umso geringer die akzeptierte Ausfallwahrscheinlichkeit.

Die Verfahren zur Vorhersage von Restlebensdauern lassen sich grundsätzlich in bauteilspezifische Methoden und anwendungsorientierte Näherungslösungen aufteilen.

Die bauteilspezifischen Methoden sind hoch spezialisiert. Sie beschäftigen sich meist mit nur einem bestimmten Bauteil, z. B. Wälzlagern oder Hochdruckleitungen. Das Ziel ist die möglichst exakte Beschreibung des Schädigungsprozesses. Mit einem enormen Anspruch an Detaillierung und Präzision werden verschiedene Beanspruchungen und die damit verbundenen Schadensbilder analysiert. Aufgrund des beträchtlichen Zeit- und Kostenaufwands sind derartige Methoden bislang eher als Domäne der universitären Werkstoffwissenschaften anzusehen, auf die hier nicht weiter eingegangen werden soll.

Anwendungsorientierte Lebensdauerprognosen

Die betriebliche Instandhaltung von Thermoprozessanlagen benötigt eine Methode, die es in der Praxis ermöglicht, die wahrscheinliche Lebensdauer von Bauteilen einfach und realitätsnah abzuschätzen. Die Methode soll im Gegensatz zu bisherigen individuellen Schätzungen zum einen die Genauigkeit und zum anderen die Transparenz und die Überprüfbarkeit der verwendeten Lebensdauern verbessern. Nicht mehr, aber auch nicht weniger. Ziel ist es also, die Restlebensdauer von präventiv instandgehaltenen werthaltigen Bauteilen mit deren Ausfallwahrscheinlichkeit zu verknüpfen.

⁴ Hierbei ist anzumerken, dass die bisher üblichen Data Mining Verfahren nur sehr eingeschränkt für technische Systeme geeignet sind.

⁵ Um Data Mining effizient zu gestalten, sollte nach Ansicht der Autoren ein konkreter Anlass in Form einer zu überprüfenden Hypothese bestehen.

Die bei dieser Methode zugrunde gelegten charakteristischen Lebensdauern (T) bzw. MTBF-Werte basieren auf Daten und Erkenntnissen aus der Literatur, eigenen Erfahrungen, externen Fachleuten und Firmeninformationen. Referenzlebensdauerdaten sind allerdings immer nur als grobe Näherung zu betrachten. Grundsätzlich ist anzumerken, dass für Bauteile in und an Thermoprozessanlagen derzeit keine allgemein zugänglichen standardisierten Referenzlebensdauern mit Angabe zu Randbedingungen existieren. Wer sollte diese bisher auch erfasst haben?

Definition der Lebensdauern

Lebensdauer ist nicht gleich Lebensdauer. Es gibt einige wichtige Unterscheidungen:

Die technische Lebensdauer ist erreicht, wenn ein Bauteil die ihm zugeordnete Funktion nicht mehr erfüllen kann, Instandhaltungsmaßnahmen nicht mehr möglich sind und das Bauteil ausgetauscht werden muss⁶. Der Abnutzungsvorrat ist zum Ende der technischen Lebensdauer vollends verbraucht.

Als charakteristische Lebensdauer wird der Zeitpunkt definiert, zu dem 63,2 % der betrachteten Population ausgefallen sind. Bei einer konstanten Ausfallrate (wenn nur Zufallsausfälle auftreten) entspricht die charakteristische Lebensdauer (T) der mittleren Lebensdauer (MTBF).

Spezifische Lebensdauern

Die tatsächliche Nutzungsdauer ist deutlich geringer als die technische oder die charakteristische Lebensdauer, weil viele Bauteile periodisch oder zustandsorientiert noch vor Überschreitung der Abnutzungsgrenze (also noch voll funktionsfähig) ausgetauscht werden. Als Zeitpunkt für eine präventive Instandhaltung wird daher eine wesentlich kürzere Lebensdauer, z. B. die B_{10} -Lebensdauer verwendet, zu dem 10 % der betrachteten Population ausgefallen sind. B_{10} -Lebensdauern (bzw. andere Lebensdauerwahrscheinlichkeiten) können aus T umgerechnet werden.

Die mit einer spezifischen Ausfallwahrscheinlichkeit verknüpfte Lebensdauer wird in diesem Beitrag spezifische Lebensdauer (B_x) genannt, wobei „x“ für den Zeitpunkt steht, zu dem „x“ % der betrachteten Population ausgefallen sind. Der Ausfallwahrscheinlichkeitswert der spezifischen Lebensdauer wird sich an den Folgen eines Ausfalls orientieren, d. h. je höher die Ausfallkosten, desto geringer die gewählte spezifische Lebensdauer.

Einflussfaktoren auf die Bauteillebensdauern

Lebensdauerangaben berücksichtigen die spezifischen Einflussfaktoren am Einbauort nicht. In der Realität zeigt sich aber, dass Abnutzungsvorräte nicht gleichbleibend

abgebaut werden und dass sich Einflussfaktoren auch recht drastisch auf die Lebensdauer auswirken können. Maximale Temperatur, Temperaturgradient, Häufigkeit der Temperaturwechsel, Ofenatmosphäre, Vibration oder Verschmutzung sind ganz offensichtliche, aber nicht die einzigen wichtigen Einflussfaktoren auf Abnutzungs- und Verschleißvorgänge bei Thermoprozessanlagen.

Lebensdauerangaben müssen also an die Gegebenheiten am Einbauort angepasst werden. Dies ist die Aufgabe der Einflussfaktoren. Sowohl die Anzahl als auch die Auswirkungen der Einflussfaktoren auf die Lebensdauer von Bauteilen sind aber unübersichtlich und kaum erforscht. Dies ist auch mit ein weiterer Grund, weshalb in Big Data bzw. Data Mining so große Erwartungen gesetzt werden.

Trotzdem, ein erfahrener Instandhalter kann ohne groß darüber nachdenken zu müssen die wahrscheinlich wichtigsten Einflussfaktorengruppen benennen. Dazu gehören die Ausführungsqualität, Betriebsbedingungen, Umfeldeinflüsse, die Nutzungsintensität und die Instandhaltungsqualität. Es kann unterstellt werden, dass sich die vorgenannten Einflussfaktoren auf die vielen verschiedenen Bauteile an einer Thermoprozessanlage unterschiedlich auswirken.

Die Erfassung der Einflussfaktoren erfolgt über die Betriebs- und Maschinendatenerfassung, die ein wichtiger Bestandteil der datengetriebenen Zustandsüberwachung sind.

Verbleibende Nutzungsdauer (Remaining Useful Life)

Eine aus der Literatur⁷ bekannte einfache Korrekturmöglichkeit der spezifischen Lebensdauer durch Einflussfaktoren ist die Einführung einer verbleibenden Lebensdauer eines Bauteils (Remaining Useful Life – RUL)⁸. Die RUL ermittelt sich durch Multiplikation der spezifischen Lebensdauer (B_x) mit den Einflussfaktoren (EF) nach der Gleichung

$$RUL = B_x \times \sum EF,$$

wobei jeder einzelne Einflussfaktor wiederum seine ganz eigene spezifische Metrik haben kann.

Die Methode wurde absichtlich sehr einfach gehalten, weil sich die Berechnung wegen der vielen Unbekannten ohnehin im Bereich von Scheingenauigkeiten bewegt. Sowohl die spezifische Lebensdauer als auch die einzelnen Einflussfaktorenwerte können immer nur Richtwerte sein, da die Bedingungen, auf denen ihre Bewertung basiert, immer unsicher und unvollständig sind.

Zustandsorientierte Lebensdauerprognosen in einer vorausschauenden Instandhaltung

Lebensdauerprognosen in einer vorausschauenden Instandhaltung setzen auf den vorgenannten Methoden

⁷ Beispielsweise DIN ISO 15686 Normenreihe für die Lebensdauerabschätzung von Bauprodukten

⁸ Siehe auch VDI-Richtlinie 2651 „Plant Asset Management in der Prozessindustrie“

⁶ Die in DIN 40041:1990-12 definierte Betriebsdauer eines Bauteils vom Anwendungsbeginn bis zum Zeitpunkt des Ausfalls ist identisch mit der technischen Lebensdauer.

auf, können dann aber auch weit darüber hinausgehen.

Die optimale Prognose soll die Beziehungen zwischen dem erwarteten Zustand eines Abnutzungsmerkmals, Ereignismustern und Einflussfaktoren analysieren und die Restlebensdauer (RUL) aktuell vorhersagen. Genau genommen soll also die Lebensdauerprognose mit einem expliziten Zeithorizont und Risikoprofilen erweitert werden. Eine solche Lebensdauerprognose ist etwas qualitativ anderes als nur Trends zu extrapolieren und in einem Dashboard die Ampelfarbe umzuschalten. Dies ist aber gar nicht so

soll und daher kaum eine Justierung möglich ist.

Die Abnutzungsgrenze und der aktuelle Bauteilzustand (Abnutzungsvorrat), die von der Instandhaltung nach eigenem Ermessen angenommen werden, hängen fast frei in der Luft. Bei jeder Inspektion muss daher entschieden werden, ob das Bauteil wenigstens bis zur nächsten Inspektion weiter betrieben werden kann oder nicht. D. h. auch die RUL wird, wenn überhaupt, bei jeder Inspektion neu justiert.

Mit der datengetriebenen Zustandsüberwachung erfasste Einflussfaktoren am Einbauort, deren Größenord-

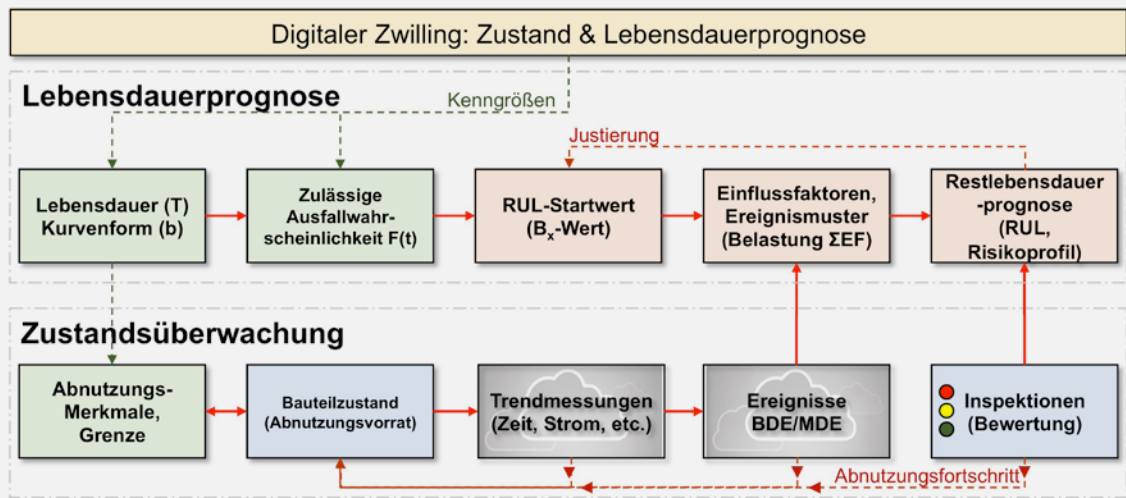


Bild 3: Module und Variablen einer zustandsorientierten Lebensdauerprognose

einfach, weil, wie in **Bild 3** gezeigt, fast alle Parameter unbekannt bzw. variabel sind.

Dies fängt schon mit den Startwerten für die Lebensdauer und Abnutzungsmerkmale an. Bisher kann kaum ein Hersteller ein Verschleißmodell für seine gelieferten Bauteile bereitstellen und behilft sich mit recht allgemein gehaltenen Wartungsanleitungen. Die Anforderungen der vorausschauenden Instandhaltung können in Zukunft helfen, solche individuellen Abnutzungs- und Verschleißmodelle aufzubauen und dazu beitragen, dass genauere Vorhersagen zu Abnutzungsvorräten, RUL oder Einflussfaktoren getroffen werden können. Schon der Weg ist das Ziel.

Wie die Abnutzung tatsächlich verläuft, ist ebenso unbekannt, weil sich schon bedingt durch vielfältige Einflussfaktoren eine große Abweichung ergeben kann. Orientierungspunkte sind daher lediglich die kaum zu bestimmenden Deltas des Abnutzungsvorrats zwischen zwei Inspektionen.

Die bauteiltypabhängigen Kenngrößen auf der Zeitachse (RUL), also die spezifische Lebensdauer bei der maximal zulässigen Ausfallwahrscheinlichkeit (B_x) und die Kurvenform (b) sind i. d. R. reine Schätzungen, auch weil die Instandhaltung das Bauteil schon vor dem Ausfall ersetzen

nungen i. d. R. bisher nicht bekannt sind, verkürzen oder verlängern die RUL. In der Praxis führt dies dazu, dass die Abnutzungsgrenze große Sicherheitsreserven beinhaltet.

Oft gibt es auffällige Ereignisse oder Ereignismuster, die mit dem Abnutzungsverlauf bzw. der Ausfallwahrscheinlichkeit und der RUL korrespondieren, z. B. zunehmende Vibration und Geräuschentwicklung. Solche wiederkehrenden Ereignismuster ermöglichen nach einigen Lernzyklen die Justierung der beiden Skalen zulässige Ausfallwahrscheinlichkeit und RUL. Darüber hinaus gibt es auch zwischen Trends und Ereignismustern Korrelationen, die eine Justierung der RUL ermöglichen.

Das Data Mining und Predictive Analytics müssen also in den Daten nach Trends, Ereignismustern und Einflussfaktoren suchen und daraus ein Prognosemodell generieren, das bauteilspezifische Aussagen zur RUL ermöglicht. Die Prognose soll mit großer Sicherheit herausfinden, wann sofort gehandelt werden muss, wenn das aus den Daten gewonnene Verhaltensmuster einen akuten Ausfall schon in kurzer Zeit erwarten lässt.

Beispiel: Einfache Lebensdauerprognose eines Gasstrahlrohrs

Manchmal geht es aber auch einige Nummern kleiner. Ein-

fache Lebensdauerprognosen mit wenigen bestimmenden Einflussfaktoren sind auch ohne die Berücksichtigung von Ereignismustern (und ohne Big Data) möglich.

In **Bild 4** ist beispielhaft die Lebensdauerprognose eines Gasstrahlrohrs mit einer charakteristischen Lebensdauer (T) von 8 Jahren und einer Kurvenform mit Formfaktor $b = 3$

von ca. 45 %. Die Lebensdauer (B_{25}) beträgt jetzt mit ca. 5 Jahren etwas mehr als das Doppelte der vorgenannten. Schon zwei Einflussfaktoren können sich also recht drastisch auf die RUL auswirken.

Der Weg in eine vorausschauende Instandhaltung beginnt schon mit kleinen Schritten. Das Beispiel sollte

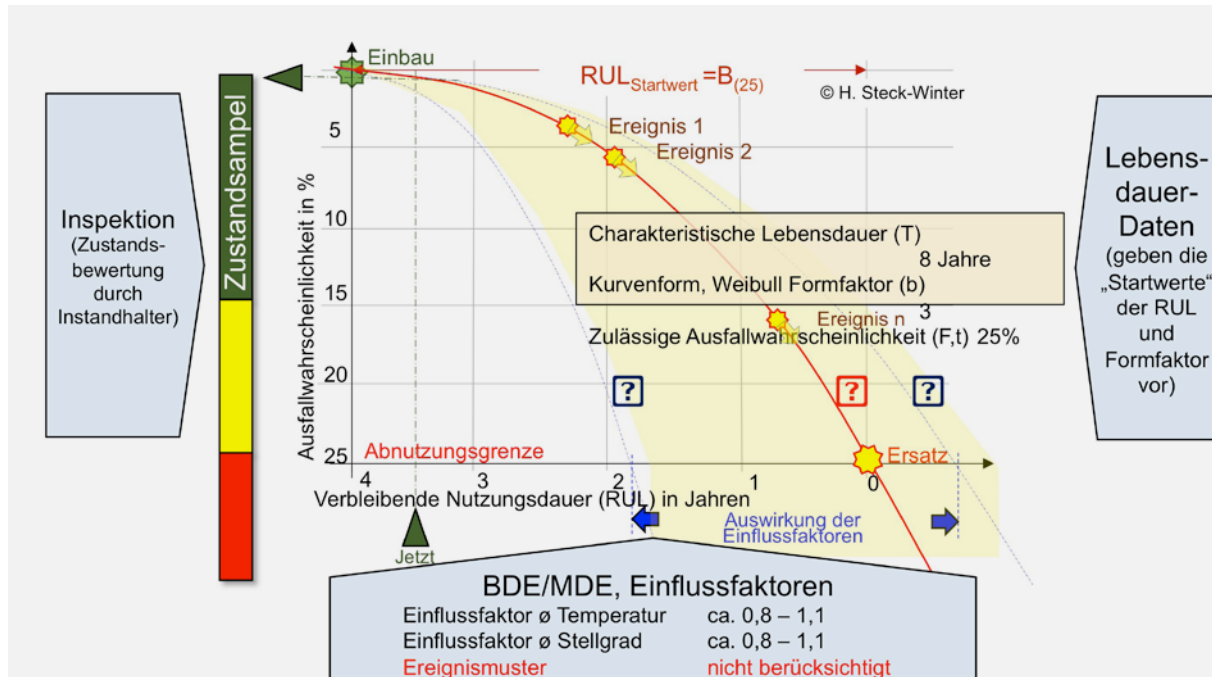


Bild 4: Lebensdauerprognose eines Gasstrahlrohrs (Prinzip)

dargestellt. RUL-Startwert ist die spezifische Lebensdauer mit einer Abnutzungsgrenze bei einer Ausfallwahrscheinlichkeit von 25 % (B_{25}).

Als Einflussfaktoren werden die Ofentemperatur und der Stellgrad berücksichtigt. Mit steigender Ofentemperatur und bei steigendem Stellgrad nimmt die Lebensdauer eines Strahlrohrs gegenüber den Referenzbedingungen ab, bei geringerer Ofentemperatur und geringerem Stellgrad nimmt die Lebensdauer zu. Die beiden Einflussfaktoren werden als Durchschnittswerte seit der letzten Inspektion berücksichtigt. Die Auswirkung der Einflussfaktoren wird mit jeweils linearen Funktionen berechnet. Das Ergebnis ist die aktuelle verbleibende Nutzungsdauer (RUL) in Jahren.

Kurve 1 zeigt die Lebensdauerprognose bei Referenzbedingungen, Durchschnittstemperatur ca. 880 °C, Durchschnittsstellgrad ca. 50 %. Die Lebensdauer (B_{25}) beträgt ca. 4,2 Jahre. Einflussfaktoren wirken sich nicht aus. Kurve 2 zeigt die Lebensdauerprognose bei erhöhter Durchschnittstemperatur von ca. 950 °C und einem Durchschnittsstellgrad von ca. 90 %. Die Lebensdauer (B_{25}) beträgt nun nur noch ca. 2,2 Jahre. Im Kontrast dazu zeigt Kurve 3 die Lebensdauerprognose bei reduzierter Durchschnittstemperatur von ca. 850 °C mit einem Durchschnittsstellgrad

zeigen, dass es oft auch einige Nummern kleiner geht. Eine datengetriebene Zustandsüberwachung und eine Lebensdauerprognose sind oft auch ohne Big Data mit deutlich geringeren Kosten möglich.

Prognosegenauigkeit der verbleibenden Nutzungsdauer

Dabei stellt sich die Frage, in welcher Genauigkeit die RUL bis zum Erreichen der Abnutzungsgrenze vorhergesagt werden muss, um sie als hinreichend zu bezeichnen. Eine Vorhersage muss der Instandhaltung mindestens genügend Zeit lassen, Instandhaltungsmaßnahmen zu planen und durchzuführen – am besten während einer regulären Wartung, mindestens jedoch mit einer Vorwarnzeit von einigen Tagen, damit Ausfälle effizient und ohne überbordende Zusatzkosten verhindert werden können [7].

Bei zu großer Unzuverlässigkeit würde die Instandhaltung ggf. viel zu früh agieren und könnte keine Abnutzung feststellen. Oder es kommt doch zu Ausfällen, weil die Prognose zu optimistisch war. Eine solche Prognose wäre dann der pure Aktionismus. In einem solchen Fall wäre ein Anwender ohne eine Prognose besser dran, da diese häufiger falsch ist als richtig.

Einen zeitlich weit entfernten Ausfall genau zu prognostizieren ist nicht realistisch, weil die Vorhersagegenauigkeit umso schlechter ist, je weiter der Ausfall entfernt ist. Gründe dafür sind, dass zum einen die Abnutzung bzw. die Zustandsverschlechterung nicht gleichmäßig sondern progressiv verläuft. Zum anderen beinhalten Zustandsüberwachungen immer eine große Unsicherheit.

Aus diesem Grund wird die Prognosegenauigkeit klassifiziert. Vorhersagen zu weit entfernten Ausfällen umfassen größere Zeitintervalle, z. B. frühestens in einem Jahr. Wenn ein Ausfall näher rückt, wird auch das Zeitintervall der RUL-Klasse enger [7].

In **Bild 5** sind beispielhaft vier RUL-Klassen, in Abhängigkeit von der Prognoseunsicherheit und der RUL, dargestellt.

Digitaler Zwilling: Cockpit für das Bauteil Life Cycle Management

Alle Bauteilinformationen müssen gut verständlich aufbereitet werden. Dies ist die zentrale Aufgabe des digitalen Zwillings. Der digitale Zwilling ist für die Instandhaltung eine Plattform, die Auskunft über den vergangenen, aktuellen und prognostizierten Zustand eines Bauteils gibt, und ein Life Cycle Management ermöglicht⁹.

Der digitale Zwilling steht für das „C“ im CPS eines Bauteils. Die physikalische Komponente (Bauteil) ist der eine Zwilling, sein Cyberobjekt der andere. Die Verbindung eines digitalen mit seinem physischen Zwilling kann durchaus einfach sein: Oft reicht eine einfache Möglichkeit zur Identifizierung, z. B. Barcode, RFID oder Data Matrix Codes, um

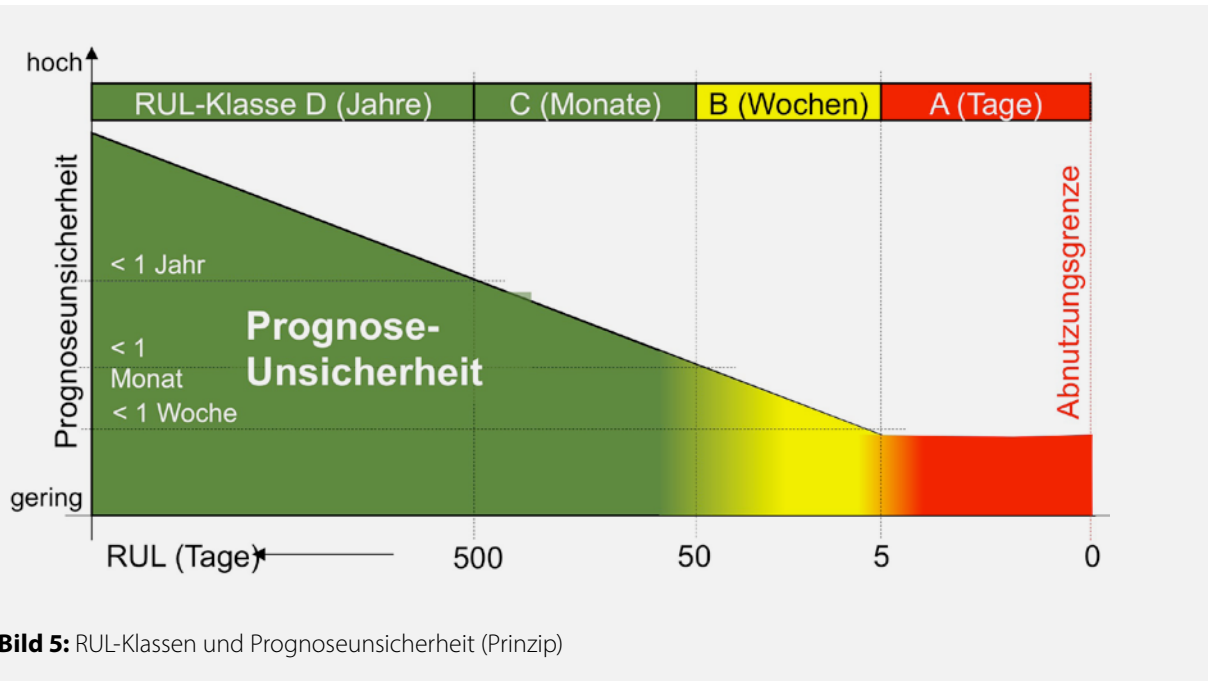


Bild 5: RUL-Klassen und Prognoseunsicherheit (Prinzip)

Eine hinreichende Prognosegenauigkeit erscheint zumindest für ein Jahr wichtig, weil damit zumindest die Zeit bis zur nächsten Jahreswartung überbrückt werden kann, bei der sich dann die nächste Möglichkeit zur Inspektion bietet.

Eine Eingruppierung in „RUL B oder A“ gibt der Instandhaltung zumindest noch die Möglichkeit, sich auf den Ausfall bzw. den Ersatz vorzubereiten und Folgeschäden zu reduzieren, wobei Fehlalarme dann natürlich besonders ärgerlich sind, weil der Aktionismus dann unnötige Kosten verursacht.

Die große Prognoseunsicherheit liegt nicht zuletzt auch daran, dass Ausfälle bzw. Abnutzungsverläufe aus der Vergangenheit meist nicht für das „Training“ des Prognosemodells verwendet werden können, weil der Bauteilzustand und die Instandhaltungsmaßnahmen nicht ausreichend dokumentiert wurden. Die Katze beißt sich an dieser Stelle sozusagen in den Schwanz.

eine Verbindung zwischen der realen und der virtuellen Welt zu schaffen. Manchmal, z. B. bei nicht beweglichen Bauteilen, braucht man diesen Link auch nicht. Durch eine Onlineverbindung wird die Aktualität sämtlicher Informationen gewährleistet.

Insbesondere für hochwertige Bauteile mit präventiver Instandhaltung sind digitale Zwillinge in einer für den Betreiber und den Servicelieferanten gleichermaßen zugänglichen Cloud eine gute Möglichkeit, das Bauteil über alle Lebensphasen, auch inklusive externer Reparaturen, zu verfolgen. Im Cyberzwilling können alle Daten und Informationen, meist mobil auf einem Tablet mit kleinen Apps, anschaulich visualisiert, ggf. auch simuliert werden, z. B. Betriebsdauer seit der letzten Wartung, Fehlerstatis-

⁹ Der digitale Zwilling ist auch ein Beispiel dafür, wie die Instandhaltung durch Augmented Reality unterstützt werden kann.

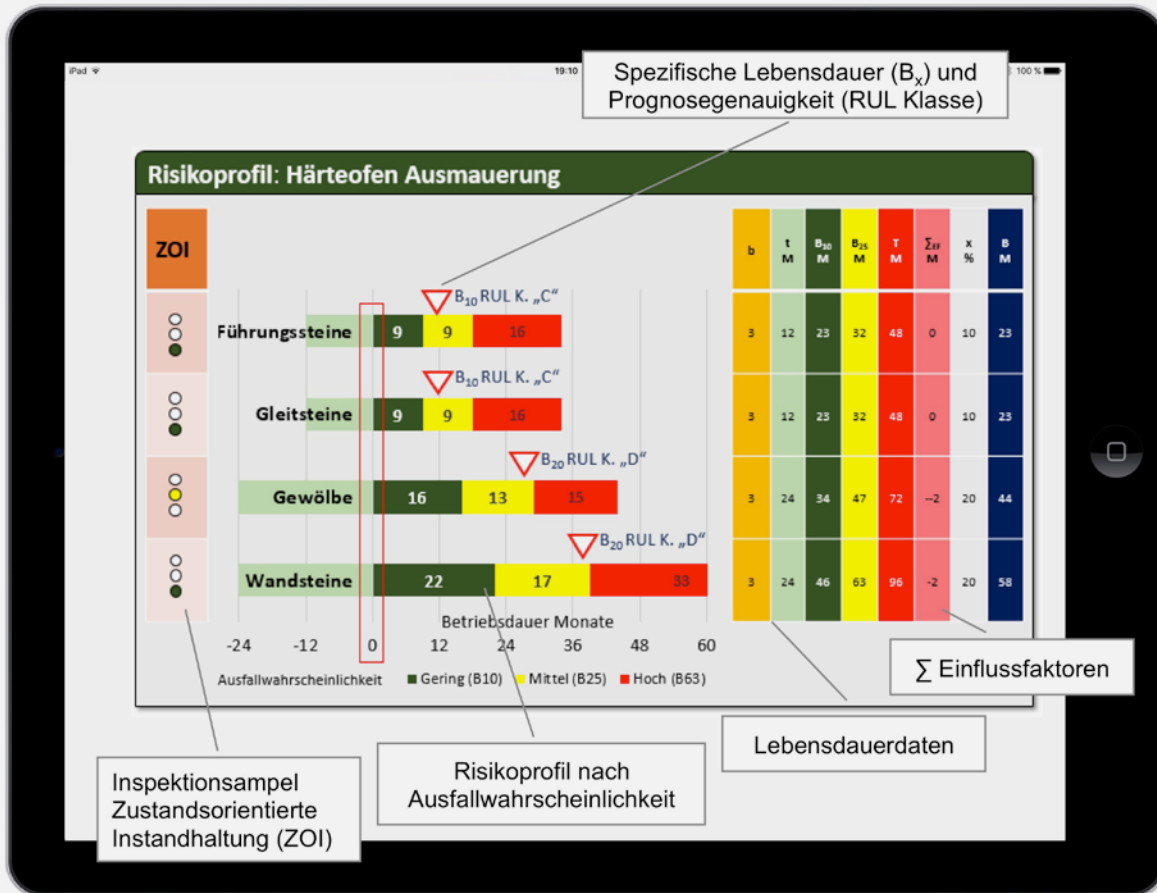


Bild 6: Risikoprofil am Beispiel einer Ofenausmauerung

Abnutzungsvorrat, Lebensdauerprognose und, wie in **Bild 6** dargestellt, auch Risikoprofile mit Instandhaltungsempfehlungen.

Prädikative Risikoprofile ergänzen die bisherige Zustandsdiagnose für eine vorausschauende Instandhaltungsplanung um die entscheidende prognostische Komponente. Sie geben der Instandhaltung die Möglichkeit, vorab zu sehen, wann der Zustand von wichtigen Bauteilen kritisch wird, aber auch wann es für Instandhaltungsmaßnahmen noch zu früh ist. Im Risikoprofil werden die Wahrscheinlichkeiten möglicher zukünftiger Ausfälle über die Nutzungsdauer angezeigt. Die zugrundeliegenden Lebensdauerdaten der Bauteile sind in einer zugeordneten Tabelle dargestellt (rechts im Bild). In einer weiteren Ampel (links im Bild) wird dem Anwender die Zustandsbewertung der Bauteile bei der letzten Inspektion (ZOI) angezeigt.

Je genauer solche Prognosen gelingen, umso zielgerichteter kann die Instandhaltung ohne nennenswerte Störung der Produktion geplant werden. Ggf. kann durch eine Veränderung der bestimmenden Einflussfaktoren eine notwendige Wartung in ein günstigeres Zeitfenster verschoben werden. Auch die Auswirkungen auf die Ersatzteil-

kosten werden erheblich sein, weil teure Ersatzteile besser disponiert werden können. Der größte Nutzen ist aber sicher, dass das Ausfallrisiko einer Anlage kalkulierbar wird.

Ausblick

Die vorausschauende Instandhaltung ist ein Schlüsselement der Industrie 4.0. Die Erwartungen an diese ergänzende Instandhaltungsstrategie sind entsprechend hoch. Die Betreiber von Thermoprozessanlagen erwarten, dass die Instandhaltungseffizienz insgesamt besser wird und dass sich die Zuverlässigkeit, Produktionsleistung und Qualität der Anlage erhöhen und sich die Instandhaltungskosten in Summe verringern. Auch für Serviceanbieter bleiben diese Erwartungen nicht folgenlos. Nachhaltiger Erfolg wird nur noch dann möglich sein, wenn das vorhandene Serviceportfolio durch vorausschauende Instandhaltung ergänzt wird.

Selbst wenn noch einige technische Hindernisse zu überwinden sind, der richtige Startzeitpunkt ist jetzt. Hauptproblem ist (noch), dass die gewonnenen Zustandsdaten oft unspezifisch sind und ein Abnutzungsproblem nur eingegrenzt werden kann. Dies ist aber besser als

nichts. Andererseits ist es aber auch gut möglich, dass aus den Daten mit fortgeschrittenen Methoden neue Informationen gewonnen werden können, die wir derzeit noch nicht sehen. Hinzu kommt, dass in den wachsenden Datenbeständen immer mehr Erfahrungswissen enthalten ist.

Keine Frage, die Zukunft der smarten Instandhaltung ist digital. Digitale Assistenten werden die Akteure bei vielen Problemstellungen unterstützen. Die umfassende Digitalisierung der Prozesse wird weiter vorangetrieben. Zustandsüberwachung (Inspektion), Ersatzteilbedarfsplanung, Wartungsplanung und Instandhaltung werden ohne Systembrüche ineinander integriert werden. Dies geht einher mit einer stärkeren Standardisierung nach innen und einer viel größeren Individualisierung nach außen.

Der Altanlagenbestand wird nicht einfach abgeschrieben. Die Möglichkeit der Modernisierung, insbesondere der Digitalisierung von „Altanlagen“, muss immer mitgedacht werden, bei Thermoprozessanlagen mit ihrer sehr langen Nutzungsdauer sollte sie sogar im Zentrum stehen, weil sie noch sehr lange Zeit in der Mehrzahl sind.

LITERATUR

- [1] Steck-Winter, H.: Sichere Thermoprozessanlagen 2.0. gwi – gaswärme international 61 (2012) Nr. 5, S. 74-80
- [2] DaimlerCrysler Corporation, Ford Motor Company, General Motors Corporation: Statistical Process Control (SPC) – Reference Manual AIAG. Detroit, 2. Auflage, 2005
- [3] Steck-Winter, H.; Unger, G.: Thermoprozessanlagen in der Fabrik der Zukunft, Teil 1 und Teil 2. gwi – gaswärme international 64 (2015) Nr. 2 und 64 (2015) Nr. 3, S. 73-81

- [4] Güntner, G.; Benisch, M.; Dankl, A.; Isopp, J. (Hrsg.): Roadmap der Instandhaltung 4.0. Salzburg, 2015
- [5] Weide, K.: Data-Mining – Aufspüren von Mustern mit Hilfe von Entscheidungsbäumen. Humboldt-Universität zu Berlin, 2012
- [6] Steck-Winter, H.; Stölting, C.: Ersatzteilbedarfsplanung für Thermoprozessanlagen. gwi – gaswärme international 65 (2016), Nr. 3, S. 55-65
- [7] Böhm, T.: Präzise Vorhersage von Weichenstörungen. Eisenbahningenieur, 2015

AUTOREN



Dr. **Hartmut Steck-Winter**, MBA
 Vormalig Aichelin Service GmbH
 Ludwigsburg
 Tel.: 0176 / 9787-3726
 steck-winter@gmx.de



Dipl.-Ing. **Carsten Stölting**, MBA
 Aichelin Service GmbH
 Ludwigsburg
 Tel.: 07141 / 6437-106
 carsten.stoelting@aichelin.com



Ing. **Günther Unger**
 Aichelin GmbH
 Mödling, Österreich
 Tel.: +43 (0)2236 / 23646-275
 guenther.unger@aichelin.com