

# Vorausschauende Instandhaltung für Thermoprozessanlagen – Teil 1: Anomalieerkennung

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

Vor ca. zwei Jahren (2018) haben wir in der gwi [1] und der PROZESSWÄRME [2] über unser Entwicklungsvorhaben „Vorausschauende Instandhaltung mit datengetriebener Zustandsüberwachung“ berichtet. Jetzt gibt es eine erste positive Bilanz. Im ersten Teil unseres Praxisbeitrags berichten wir über unser smartes Condition Monitoring (CM) zur automatischen Anomalieerkennung von ausfallkritischen Baugruppen. Die Signalvorverarbeitung erfolgt mit für Thermoprozessanlagen speziell entwickelten Methoden. Für die Überwachung und Prognose haben wir unser Prozessüberwachungssystem FOCOS 4.0 mit einem CM-Modul ergänzt. Das CM-Modul ist in eine statistische Prozesskontrolle eingebunden. Zustandsmeldungen und Anomalien werden in einem Cockpit übersichtlich visualisiert. Wie genau dies alles in der Praxis zusammenwirkt und welche Ergebnisse wir jetzt vorzeigen können, wird in diesem Beitrag beschrieben.

## Predictive maintenance for heat treatment plants – part 1: anomaly detection

About two years ago (2018) we reported in gwi [1] and PROZESSWÄRME [2] about our development project “Predictive maintenance with data-driven condition monitoring”. Now there is a first positive balance. In the first part of our article, we report on our smart Condition Monitoring System (CM) for automatic anomaly detection of failure-critical assemblies. The signal preprocessing is carried out using methods specially developed for heat treatment plants. For monitoring and forecasting, we have supplemented our process supervising system FOCOS 4.0 with a CM module. The CM module includes a statistical process control system. Status reports and anomalies are clearly visualised in a cockpit. How exactly all of this works together and what results we can now present is described in this article.

In vielen Fachbeiträgen wird vorausschauende Instandhaltung, englisch „Predictive Maintenance“ (PdM) über englische Schlagworte definiert, manchmal sogar geradezu erschlagen. Typische Beispiele sind „Analytics, Artificial Intelligence (AI), Anomaly Detection (AD), Machine Learning (ML), Time to Failure Analysis (TTF), Remaining Useful Life Estimation (RUL)“, etc. Die Liste ließe sich noch sehr viel weiter fortsetzen.

### Was genau ist eine vorausschauende Instandhaltung?

Nach unserer Definition ist PdM eine Instandhaltungsstrategie und -methode, die auf der Analyse von Prozess-,

Betriebs-, Maschinen- und Instandhaltungsdaten basiert, und Anomalieerkennung (AD), statistische Daten und -Methoden, aber auch traditionelle präventive Instandhaltungsstrategien einschließt und sich dabei moderner Industrie 4.0 Techniken bedient. PdM ist insofern eine Kombination bekannter und neuer Methoden.

Weil große Datenmengen, Algorithmen und Informationsverarbeitung mit den Techniken der vorgenannten Schlagworte dabei wichtige Rollen spielen, wird die vorausschauende Instandhaltung auch die Instandhaltungsstrategie der Industrie 4.0 genannt.

Für die betriebliche Instandhaltung ist PdM eine Methode zur Vorhersage von ungeplanten Ausfällen ausfallkriti-

scher Bauteile mit dem Ziel, solche Ausfälle durch geplante, präventive Instandhaltungsmaßnahmen zu verhindern, zumindest aber deren negative wirtschaftliche Folgen zu reduzieren. PdM ist eine strategische Methode. Sie stellt anstelle von reaktivem Korrigieren die vorausschauende Vermeidung von Ausfällen in den Vordergrund [3]. Betriebswirtschaftlich geht es bei PdM immer um eine Verbesserung der technischen Verfügbarkeit bei gleichzeitig geringeren Instandhaltungskosten.

### Condition Monitoring: Definition und Theorie

CM zur Anomalieerkennung ist die kontinuierliche Zustandsüberwachung von Bauteilen durch Messung von physikalischen Größen (z. B. Schwingungen, Temperaturen, Strom), im Weiteren „Zustandsmerkmale“ genannt, mit Hilfe von Sensoren. Dabei geht es um die Erkennung von i. d. R. sehr langsamen Zustandsveränderungen mit physikalischen Ursachen, z. B. Erosion, Korrosion oder tribologischer Verschleiß.

CM liegt die Theorie des P-F-Intervalls der zuverlässigkeitsorientierten Instandhaltungsstrategie zu Grunde [4]. Dabei wird vorausgesetzt, dass einem nicht zufälligen Ausfall „F“ (Failure) ein potenzieller Fehler „P“ (Potential Failure), also eine Abweichung vom „Normalzustand“ vorausgeht und die P-F-Intervallzeit als Vorwarnzeit genutzt werden kann. Der Gutzustand ohne Zustandsveränderung dauert i. d. R. lange an, oft mehrere Jahre. Die P-F-Intervallzeit ist demgegenüber vergleichsweise kurz, oft nur wenige Tage oder gar nur Minuten. Condition Monitoring zur Anomalieerkennung ist also ein Frühwarnsystem gegen unerwartete Ausfälle.

An Thermoprozessanlagen wird CM zur Anomalieerkennung hauptsächlich eingesetzt, weil die Inspektionsintervalle einer Jahreswartung typischerweise zu lange sind, um sich anbahnende Zustandsverschlechterungen rechtzeitig zu erkennen. Wichtigste Ziele des CM sind demzufolge, einen bevorstehenden Bauteilausfall mit ausreichender Vorwarnzeit zu melden, um größeren Schaden zu vermeiden, aber auch Abnutzung und Verschleiß kontinuierlich zu messen.

### Industrielle Thermoprozessanlagen: Was ist daran so besonders?

Industrielle Thermoprozessanlagen haben einige Spezifika, die sie auch im PdM-Kontext deutlich von Maschinen unterscheiden. Insbesondere sind (fast) alle ausfallkritischen Bauteile im Ofen eingebaut. Im Ofen ist aber schon wegen der hohen Temperatur kein CM mit Sensoren möglich. Zustandsinspektionen sind i. d. R. nur jährlich bei kaltem Ofen durchführbar. Im laufenden Betrieb sind Ofenanlagen eine Blackbox, aus der Zustandsinformationen nur indirekt gewonnen werden können. Konzepte aus dem Maschinenbau sind daher i. d. R. nicht übertragbar.

Ein weiteres sehr wichtiges Unterscheidungsmerkmal ist, dass Thermoprozessanlagen wegen der sehr hohen

Ausfallfolgen meist nach einer s. g. RCM-Strategie<sup>1</sup> gewartet werden. Ausfälle bzw. deren Ursachen werden, soweit es irgendwie geht, präventiv verhindert.

### Um welche Baugruppen und Bauteile geht es?

Anders als im Maschinenbau, bei dem CM meist nur auf einer Schwingungsdiagnose der Bearbeitungsachsen basiert, haben wir alle Bauteile in den Blick genommen, deren unerwarteter Ausfall hohe Folgekosten verursachen könnte.

Wegen der für Thermoprozessanlagen spezifischen Besonderheiten betrachten wir ausfallkritische Bauteile immer in ihrem Funktionszusammenhang der jeweiligen Baugruppe. Eine Baugruppe ist eine Funktionseinheit aus mehreren Bauteilen. Sie ist ausfallkritisch, wenn mindestens eines ihrer Bauteile ausfallkritisch ist. Solche Baugruppen in und an konventionellen Thermoprozessanlagen sind z. B. Hub- und Senkbühnen, Transportsysteme, Türen, etc.

Die Zustandserfassung auf Baugruppenebene hat Vor- und Nachteile. Nachteilig ist, dass die Beteiligung eines Bauteils an einer Zustandsänderung der Baugruppe nur als Wahrscheinlichkeitswert ausgedrückt werden kann. Welches Bauteil für die Zustandsveränderung verantwortlich ist, kann erst bei einer Inspektion eindeutig bestimmt werden. Der große Vorteil ist jedoch, dass der Funktionszusammenhang nie aus dem Blick gerät.

### Infrastruktur und Nachrüstungen

**Bild 1** zeigt das Layout einer Gasaufkohlungs-Durchstoßofenanlage, die uns als Pilotanlage zur Erprobung gedient hat. Die farbigen Rechtecke zeigen das aktuelle CM-Zustandsmonitoring.

Unser Ziel war, die vorausschauende Instandhaltung auch für „Altanlagen“ verfügbar zu machen. Der Nachrüstungsaufwand soll hier nicht kleingeredet werden. Er ist aber sehr davon abhängig, welche Analysetiefe mit dem CM erreicht werden soll und welcher Automatisierungsgrad bereits vorhanden ist.

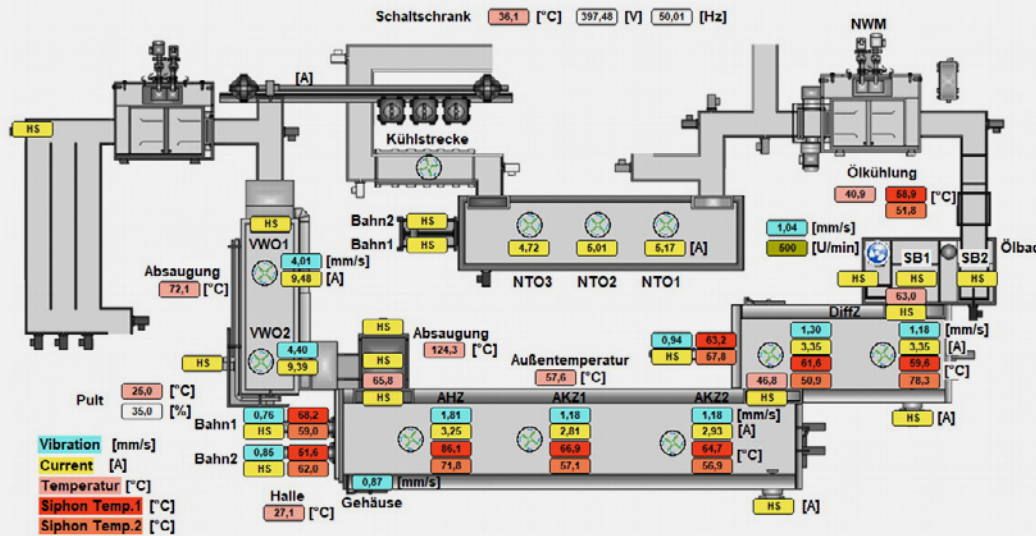
Die für das CM benötigten zusätzlichen Sensoren werden an eine Interface-SPS mit sehr schneller Verarbeitungsgeschwindigkeit angeschlossen, die mit dem FOCOS CM-Modul verbunden ist. Ein Eingriff in die Anlagenautomatisierung ist dafür nicht erforderlich. Bei der beschriebenen Anlage erfolgte die Nachrüstung im laufenden Betrieb.

### FOCOS 4.0 mit CM-Modul

Als IT-Plattform haben wir unser seit Jahren bewährtes Prozessüberwachungssystem FOCOS<sup>2</sup> 4.0 gewählt und es mit einem CM-Modul erweitert. Dies hat den Vorteil, dass wir auf einem ausgereiften System aufsetzen, in dem

<sup>1</sup> Reliability Centered Maintenance, deutsch: Zuverlässigkeitsorientierte Instandhaltung

<sup>2</sup> FOCOS steht für Furnace Operating and Optimization System. In der IoT-Terminologie ist FOCOS ein on-premise Edge Computer.



**Bild 1:** Layout der Pilotanlage mit CM-Zustandsanzeigen

schon alle Betriebs- und Maschinendaten vorliegen und das insbesondere über blitzschnelle Erfassungs- und Analysemöglichkeiten großer Datenmengen verfügt. Es geht ausdrücklich nicht nur um Zustandsdaten.

Das CM-Modul fügt sich nahtlos in die Basisfunktionalität von FOCOS 4.0 ein. Der Auswertzeitraum der Zustandserfassung ist nicht begrenzt, auch wenn ggf. sehr viele Daten ausgewertet werden müssen. Kleinere Zeitbereiche können zwischen zwei Linealen eingegrenzt werden. Im eingegrenzten Zeitbereich werden dann sofort alle Kennwerte der Zustandsvariablen berechnet, beispielsweise Minimal, Durchschnitt, Maximal, Gradient, Integral, etc. Beide Lineale können synchron über den ganzen Zeitraum verschoben werden. Mit einer Lupe kann sowohl die Variable als auch der Zeitbereich beliebig gezoomt werden. Auch die Chargenverfolgung wird angezeigt. Der Produktionseinfluss auf die Zustandsvariablen kann so einfach nachvollzogen werden.

## Erfassungsmethoden und Zustandsmonitoring

In diesem Kapitel wenden wir uns nun den Zustandserfassungsmethoden und dem -monitoring zu.

Die Erfassungsmethoden sind das Fundament, mit dem jedes CM steht oder fällt. Die wichtigste Aufgabe des Monitoring ist, Abnutzung und Verschleiß sichtbar zu machen.

Wie schon einleitend ausgeführt, ist eine Zustandserfassung mit Sensoren im Ofen nur indirekt über den Funktionszusammenhang der beteiligten Bauteile in einer Baugruppe möglich. Abnutzungsbedingte Zustandsveränderungen benötigen i. d. R. sehr lange Zeit, entwickeln sich dann aber nach dem Auftreten der ersten potenziellen Probleme oft recht rasch bis zum Ausfall (vgl. P-F-Intervall). Das Monitoring der erfassten Zustandsvariablen muss daher sowohl

über sehr lange Zeiträume (Jahre) als auch über sehr kurze Zeitintervalle (Millisekunden) möglich sein.

Unser CM basiert im Wesentlichen auf vier speziell für Thermoprozessanlagen entwickelten Methoden: (1.) einer hochauflösenden Strommessung für Antriebssysteme mit Asynchronmotoren, (2.) einer hochgenauen Zeitmessung der Bewegungsabfolgen, (3.) einem Control Performance Monitoring der Regelkreise und (4.) einer Prozessdatenvvalidierung der Stoffströme.

Traditionelle CM-Sensoren, beispielsweise für Schwingung oder Oberflächentemperatur, spielen natürlich auch eine Rolle.


### Strommessung für Asynchronmotoren

Die am häufigsten vorkommenden ausfallkritischen Baugruppen sind Antriebssysteme mit Asynchronmotoren, beispielsweise Türantriebe, Durchstoßer, Querstoßer, Senkbühnen, etc.

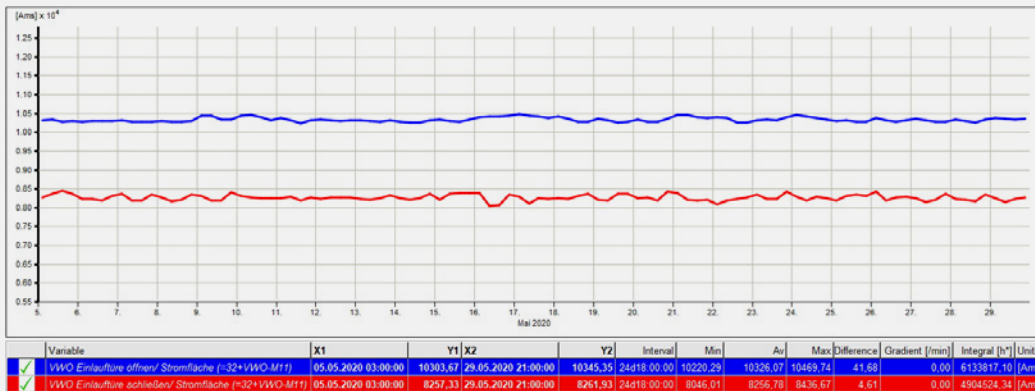
Abnutzung und Verschleiß der beteiligten Bauteile haben einen Einfluss auf die Belastung und den daraus resultierenden Schlupf des Motors. Asynchronmotoren haben bauartbedingt einen Schlupf, d. h. der Rotor hinkt dem Drehfeld in Abhängigkeit von der Belastung etwas hinterher, versucht aber gleichzeitig den Schlupf durch eine höhere Stromaufnahme zu verringern. Die Stromaufnahme gibt also Auskunft über die Belastung. Die Strommessung erfolgt über im Schaltschrank eingebaute Stromwandler. Sie ist eine preisgünstige Methode, weil der Materialeinsatz gering ist und keine Installationsarbeiten außerhalb an der Anlage erforderlich sind.

### Stromaufnahme von Dauerläufern

Die Stromaufnahme von Dauerläufern (Motoren, die dauernd in Betrieb sind), beispielsweise Gasumwälzer oder



**Bild 2:** Monitoring des Stromverlaufs der Ofen-Einlauffür als Taktfolge



**Bild 3:** Monitoring des Stromverlaufs der Ofen-Einlauffür als Liniendiagramm

Umwälzpumpen, ist auch wesentlich von der Medientemperatur bzw. deren Viskosität abhängig. D. h. es muss entweder eine „einfache Temperaturkompensation“ vorgesehen oder auf eine weniger beeinflusste Methode, beispielsweise Schwingungsüberwachung, ausgewichen werden.

### Strommessung von getakteten Antrieben

Die Strommessung von getakteten Antrieben ist eine Herausforderung. Ein Stromverlaufsmuster während der Bewegung zeigt sich, wie in **Bild 2** ersichtlich ist, erst bei einer sehr schnellen Strommessung mit einer Abtastgeschwindigkeit von nur wenigen Millisekunden. Das bedeutet, dass für einen einzigen Bewegungszyklus, beispielsweise ca. 15 s für Heben und Senken einer Ofentür bei einer Abtastrate von 3 ms ca. 2.500 Datensätze verarbeitet werden müssen. Bei einer Taktzeit von 15 min sind dies am Tag nur für diese Bewegung schon 240.000 Datensätze. Big Data steht da schon in der Tür.

Getaktete Antriebe können prinzipiell in Antriebe mit und ohne Chargentransport unterschieden werden. Antriebe ohne Chargentransport, i. d. R. Türantriebe, werden von Chargen nicht beeinflusst. Zustandsveränderungen sind daher einfacher zu erkennen. Antriebe mit Chargentransport, beispielsweise Durchstoßer, Querstoßer, etc.,

stellen höhere Anforderungen an das CM, weil sowohl das Chargengewicht als auch die Gegenkörper der Transporteinrichtung (beispielsweise der Reibwert der Gleitschienen) zu berücksichtigen sind.

Ein getakteter Antrieb läuft im Schrittablauf immer nur wenige Sekunden, beispielsweise zuerst ca. 7 s Tür öffnen und ca. 30 s danach ca. 7 s Tür schließen. Der Türantrieb hat dann in Abhängigkeit von der Taktzeit einige Minuten Pausenzeit. Es gibt also keinen kontinuierlichen Stromverlauf.

Für das CM wird sowohl der Summenstrom berechnet als auch das Stromverlaufsmuster analysiert. Der Summenstrom entspricht der Fläche unter der Kurve, also dem Integral, und ist proportional zur benötigten Antriebsleistung der gesamten Bewegung. Wenn der Summenstrom einer Bewegung, wie in **Bild 3** dargestellt, als einzelner Punkt dargestellt wird, kann man die Punkte verbinden und erhält ein Liniendiagramm (Tür heben blau, Tür senken rot), das im Monitoring angezeigt wird. Zustandsveränderungen, auch über sehr lange Zeit, können so anschaulich visualisiert werden.

### Zeitmessung von getakteten Antrieben

Zeitmessung ist sensorlos. Die SPS verfügt über eine hochgenaue Uhr, die zur Bewegungszeitmessung genutzt werden kann. Zeitmessung ist damit die preisgünstigste und

einfachste Methode zur Zustandsüberwachung von taktgesteuerten Antrieben.

Die erwartbaren schlupfbedingten Bewegungszeitschwankungen sind allerdings sehr klein (ca. 1 bis 3 % der Bewegungsdauer). Ein Verlaufsmuster über die Bewegungsdauer ist im Gegensatz zum Stromverlauf nicht darstellbar. Auch die schlupfbedingte Bewegungsdauerveränderung ist im Gegensatz zum Strommessung deutlich geringer ausgeprägt. Bezüglich der Analysemöglichkeiten kann also eine Zeitmessung der Bewegungsdauer eines Asynchronmotors die (sensorbasierende) Strommessung nicht ersetzen.

Strom- und Zeitmessung können aber miteinander korreliert werden und sich damit gegenseitig plausibilisieren.

### Control Performance Monitoring

Für das CM von Regelstrecken, beispielsweise Heizungsregelungen, haben wir unsere neu entwickelte, sensorlose Methode des Control Performance Monitoring (CPM) eingesetzt. Dabei werden sowohl der Stellgrad des Reglers als auch der Temperaturgradient der Regelstrecke in einem zeitweisen stationären Zustand als Zustandsvariablen ermittelt. Beispielsweise sind im stationären Zustand die Gradienten der Abkühlung kennzeichnend für den Zustand der Isolation und die Wärmeverluste oder der Stellgrad der Heizungsregelung für die Leistung der Beheizungseinrichtung.

Sobald das CPM einen stationären Zustand erkennt, werden, wie in **Bild 4** dargestellt, der Stellgrad und der Temperaturgradient registriert. Trends bzw. Veränderungen sind so schon im Monitoring ohne komplexe Auswertungsmethoden mit Berücksichtigung der vielfältigen Einflussfaktoren sichtbar.

### Prozessdatenvalidierung

Für alle Baugruppen mit Stoffströmen, beispielsweise Wärmetauscher, haben wir die Methode der Prozessdaten-

validierung (PDV) für Thermoprozessanlagen adaptiert. Wärmetauscher, als Blackbox betrachtet, haben einen funktionalen Zusammenhang zwischen Eingangstemperatur, Ausgangstemperatur und Wärmeabgabe.

Verändert sich die Ausgangstemperatur bei bekannten messbaren Einflussfaktoren außerhalb des bekannten Funktionszusammenhangs, liegt eine Veränderung in der Blackbox vor. Beispielsweise steigt die Ausgangstemperatur bei gleichbleibender Eingangstemperatur, weil der Wärmetauscher verschmutzt ist.

### Gehäuseschwingungen


Gehäuseschwingungen sind häufig ein Verschleißtreiber. Für ihre Erfassung haben wir Schwingungssensoren an Gehäusen befestigt. Das Ofengehäuse hat beispielsweise durch die angebauten Umwälzer und Ventilatoren eine permanente Grundschiwingung, die, wie die Erfahrung zeigt, wenn sie ein zulässiges Niveau übersteigt, die Standzeit der Ofenmauerung gravierend herabsetzt.

Transportbewegungen wirken sich auf den ersten Blick diffus im Schwingungsmuster aus, liefern aber wertvolle Zustandsinformationen, beispielsweise bei Übergängen.

### Smartes Condition Monitoring

Bis hierhin haben wir über Zustandserfassung und Monitoring berichtet. Dies ist aber noch kein smartes CM. Zum smarten CM wird Zustandserfassung und Monitoring erst durch Anomalieerkennung und Prognose. Wenn nämlich die betriebliche Instandhaltung mit Vorlaufzeit erfahren kann, wann ein Bauteil bzw. eine Baugruppe wahrscheinlich ausfällt, kann sie rechtzeitig Gegenmaßnahmen einleiten. Das ist immer wirtschaftlicher als abzuwarten, bis etwas nicht mehr optimal funktioniert oder gar ausfällt.

Der Grundgedanke unseres smarten CM ist daher auch schnell erklärt. Alle Zustandsvariablen einer Baugruppe



**Bild 4:** Stellgrad und Temperaturgradient im stationären Zustand

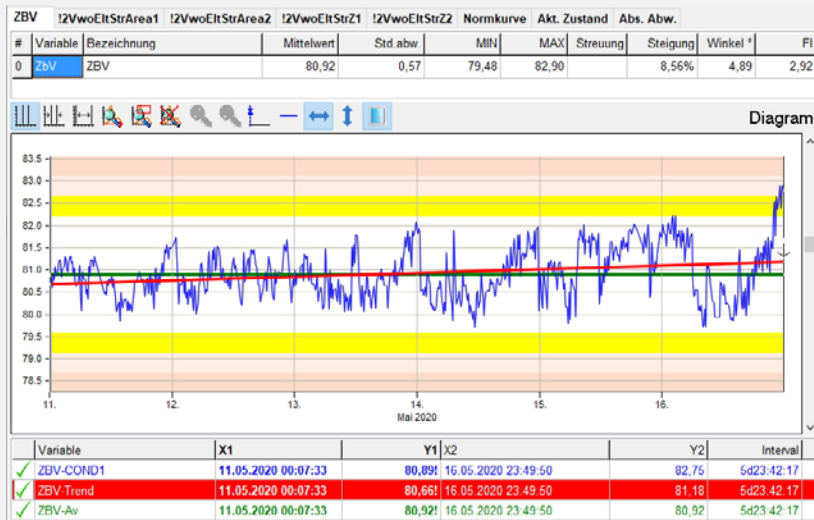


Bild 5: Ampelchart

werden, wie vorstehend beschrieben, kontinuierlich aufgezeichnet und zur Überwachung und Zustandsdiagnose in eine elektronische Prozesskontrollkarte eingespeist. Bei einem Vorlauf<sup>3</sup> werden auf Basis der natürlichen Streuung ein Mittel- bzw. Erwartungswert, Warn- und Eingriffsgrenzen berechnet und in einem Ampelchart angezeigt. Langwierige Grenzwerteinstellungen sind nicht erforderlich, unser smartes CM parametrieren sich mit einem AI-Algorithmus selbst. Die aktuellen Zustandsmessungen werden mit dem Erwartungswert verglichen. Anomalien werden so zuverlässig erkannt, Trends werden für Prognosen ausgewertet.

Die wichtigsten Bestandteile unseres smarten CM werden im Folgenden kurz beschrieben:

### CM-Fähigkeit

Nicht jede Zustandsvariable ist auch CM-fähig. Die CM-Fähigkeit wird, ähnlich wie die Prozessfähigkeit, in SPC kontinuierlich berechnet und in dem Ampelchart als Fähigkeitsindex (FI) angezeigt.

Ist die natürliche Streuung zu groß, geht ein P-F-Intervall ggf. im Rauschen unter. Ein Ausfall kommt dann scheinbar zufällig ohne jede Vorwarnung. Dann ist mit dieser Zustandsvariable kein CM möglich.

### Vorlauf bzw. Erwartungswert

Ein Vorlauf ist das Spiegelbild der natürlichen Streuung einer Zustandsvariablen im Gutzustand, also im ungestörten Produktionsbetrieb. Er wird durch den Mittelwert und die Standardabweichung charakterisiert. Der Mittelwert dient als Erwartungswert für das CM im laufenden

3 Der aus dem SPC übernommene Begriff „Vorlauf“ als Erwartungswert ist etwas irreführend. Tatsächlich ist der Vorlauf eine nachträglich ausgewählte Stichprobe, die den Gutzustand (als Vergleichsgröße) repräsentiert. Wir nennen den Erwartungswert daher auch oft Normkurve.

Betrieb. Die Standardabweichung ist die Basis für die Berechnung der Warn- und Eingriffsgrenzen. Wir nennen den Erwartungswert mit seinen Warn- und Eingriffsgrenzen daher manchmal auch Normkurve.

Mit jedem neuen Vorlauf, beispielsweise nach einer Wartung, wird die bisherige Normkurve einer Zustandsvariablen mit einem Algorithmus neu berechnet. Sie wird dann bis zum nächsten Vorlauf fixiert. So lässt sich sowohl der Aufwand für die Parametrierung des CM als auch die Anzahl der Fehlalarme signifikant reduzieren. Gerade die Reduzierung von Fehlalarmen

trägt wesentlich zu höherer Akzeptanz bei, da bei zu häufigen Fehlalarmen alle weiteren Meldungen mit einem Schulterzucken abgetan und weggedrückt werden [5].

### Zustandsbestimmende Variable

Die Zustandsbestimmende Variable (ZbV) repräsentiert den momentanen „CM-Gesundheitszustand“ der Baugruppe in Relation zum Erwartungswert. Sie wird aus allen Zustandsvariablen einer Baugruppe, beispielsweise Antriebsstrom, Bewegungsdauer, Gehäuseschwingung und Oberflächentemperatur berechnet.

### Ampelchart

Mit dem Begriff „Ampelchart“ soll zum Ausdruck gebracht werden, dass eine Zustandsvariable im Zeitverlauf zwischen einem Erwartungswert (grün) und in positiver und negativer Richtung zwischen einer Warn- und einer Eingriffsgrenze (gelb und rot), also den drei Ampelfarben, pendeln kann.

In dem in **Bild 5** dargestellten Ampelchart werden der Erwartungswert (grün), Warn- und Eingriffsgrenzen (gelb und rot) mit den neuen Messwerten einer Zustandsvariablen verglichen.

Der Messbereich wird aufgespreizt, d. h. im Chart wird nur die Schwankung der Zustandsvariablen (blau) um den Erwartungswert angezeigt. Die Warn- (gelb) und Eingriffsgrenzen (rot) werden +/- um den Erwartungswert positioniert. Der Trend im ausgewählten Zeitbereich wird durch eine rote Linie visualisiert.

### CM-Kurvenverlaufsmusteranalyse

Ein CM-Kurvenverlaufsmuster hat gegenüber allen anderen Zustandsvariablen einen herausgehobenen Informationsgehalt. Muster sind, wie beispielhaft in **Bild 6**

dargestellt, dynamische und scheinbar chaotische Kurvenformen, die sich während eines taktgesteuerten Bewegungsvorgangs einstellen, beispielsweise während einer Türbewegung.


Der Summenstrom aus der Fläche unter der Kurve kann die Kurvenform nicht auswerten. Es ist beispielsweise möglich, dass bei einer Bewegung aufgrund ruckender Gleiteigenschaften schnelle Schwingungen nach oben, danach aber sofort immer wieder (chaotische) Entlastungen nach unten erfolgen. Damit ergeben sich zwar nur kleine oder gar keine Abweichungen in der Flächenerfassung, aber große Abweichungen in der Kurvenform, die möglicherweise wichtige Zustandsinformationen beinhalten. Das Kurvenverlaufsmuster hat also einen größeren Informationsinhalt.

Eine Mustererkennung beinhaltet im Wesentlichen eine Merkmalsextraktion und eine Klassifikation. Merkmale sind beispielsweise die Kurvenkontur oder die Volatilität. Klassifikationen sind die Ausprägung der Merkmale, beispielsweise die Anzahl der Konturüberschreitungen.

Aus allen klassifizierten Merkmalen wird die Zustandsvariable „CM-Muster“ gebildet, die ebenfalls bei der Berechnung der ZbV berücksichtigt wird.

Einen sehr tiefen, i. d. R. Analysten vorbehaltenen Einblick in Zustandsveränderungen über die Zeit ermöglicht das Übereinanderlegen verschiedener Stichproben wie in **Bild 7** dargestellt. Das Beispiel zeigt das Stromverlaufsmuster eines Querstoßers. Die für den Querstoßer typischen Übergänge der Gleitsteine und im Kettenkanal sind im Muster deutlich erkennbar. Sie korrespondieren auch mit dem Schwingungsmuster am Querstoßergehäuse.

Die Herausforderung einer Kurvenverlaufsmusteranalyse ist neben der online Merkmalsextraktion der Datenumfang. Schon für eine einfache Querstoßerbewegung kann



**Bild 6:** CM-Stromverlaufsmuster Ofen-Einlauftür heben


der Vergleich einer aktuellen Kurvenform mit den Erwartungswerten schnell einige hunderttausend Datensätze am Tag überschreiten.

### Cockpit für den Praktiker

Das Cockpit soll die Instandhaltung dabei unterstützen, abnormales Verhalten einer Baugruppe intensiver in den Blick zu nehmen. Im in **Bild 8** dargestellten CM-Cockpit werden die wichtigsten CM-Parameter Trend, Aktivität und Mittelwertabweichung für den Praktiker einfach und trotzdem mit der notwendigen Informationstiefe visualisiert.

### Trend

Der Trend zeigt, in welche Richtung und wie ausgeprägt sich eine Zustandsvariable mit der Zeit verändert. Zusätzlich wird die Zeit berechnet, bis eine Eingriffsgrenze des Ampelcharts verletzt wird. Der Trend einer Zustandsvariablen wird durch die Steigung einer Regressionsgeraden zwischen allen Messpunkten in einem ausgewählten Zeitraum bestimmt. Der Trend gibt der Instandhaltung also eine Idee davon, ab wann mit einem abnormalen Verhalten der Baugruppe zu rechnen ist.



**Bild 7:** CM-Stromverlaufsmuster Querstoßer vorfahren mit übereinandergelegten Stichproben



**Bild 8:** CM-Cockpit

### Aktivität

Die Aktivität zeigt auf, wie dynamisch eine Zustandsvariable zwischen ihrem Erwartungswert und ihren Warn- und Eingriffsgrenzen hin und her pendelt. Die Aktivität gibt einen Hinweis auf die Wahrscheinlichkeit der in nächster Zeit möglichen Zustandsveränderungen.

### Mittelwertabweichung

Eine andauernde Mittelwertabweichung (MW-Abw.) ist ein Indiz dafür, dass eine Zustandsvariable anhaltend von ihrem Erwartungswert (Normkurve) abweicht, beispielsweise weil sich die Belastungssituation eines Antriebssystems verschleißbedingt erhöht hat.

### Zustandsampel

Die CM-Zustandsampel gibt dem Praktiker einen schnellen Überblick über den „Gesundheitsstatus“ einer Zustandsvariablen. Grün beschreibt einen Zustand, der nicht von seinem Erwartungswert abweicht. Rot beschreibt einen vom Erwartungswert stark abweichenden Zustand, also eine Anomalie, beispielsweise wenn sich der Mittelwert der ZbV verschoben hat und es zu permanenten Verletzungen der Warn- und Eingriffsgrenzen kommt. Die Ampelfarben Gelb und Rot sind also ein Hinweis darauf, dass eine Baugruppe entweder bei nächster Gelegenheit oder sehr bald inspiziert werden sollte.

### Die unverzichtbare Rolle der Instandhalter und Analysten

Die Daten des Ampelcharts und des Cockpits geben der Instandhaltung wie vorstehend ausgeführt einen schnellen Überblick über den Zustand ausfallkritischer Baugruppen. Sie können auch mobilen Instandhaltungsassistenten über eine Schnittstelle zur Verfügung gestellt werden.

Für eine tiefergehende Interpretation des CM ist dann aber eine gute Kenntnis der Anlagen notwendig, da Zustandsdaten meist eine Reihe von Abhängigkeiten aufweisen, die nur von einem geschulten Instandhalter beurteilt werden können [4]. Aber auch mit AI-Unterstützung lassen sich nicht alle Anomalien vorhersagen. Da wollen wir keinem etwas vormachen!

Datenanalyse ist ein Fachgebiet, das nur von leistungsfähigen Herstellern oder Servicelieferanten als Dienstleistung

angeboten werden kann. Ein guter Zeitpunkt für eine Datenanalyse ist – neben der Remote-Unterstützung bei einer anstehenden Störung – beispielsweise vor einer Jahreswartung, um potenzielle Schwachstellen oder Risiken aufzudecken.

CM zur Anomalieerkennung ist also viel mehr als nur bereits Vorhandenes irgendwie zusammenzubringen und mit einer Ampel zu signalisieren, sondern braucht

eine technologische Infrastruktur, Sachverstand und ein durchgängiges Konzept, um einen echten Mehrwert zu schaffen.

### Zustandsrückmeldungen

Ohne Zuordnung eines CM-Signalpegels zu einem bei einer Inspektion erfassten physikalischen Zustand hängt das CM so wie eine nicht geeichte Waage in der Luft. Das CM kann dann zwar eine Zustandsveränderung erkennen und auch überwachen, aber keine Aussage darüber machen, ob die Zustandsänderung kritisch ist.

Ohne Rückmeldungen und Klassifizierungen durch die Instandhaltung, beispielsweise über die bereits erwähnte Schnittstelle mit einem mobilen Instandhaltungsassistenten, läuft eine vorausschauende Instandhaltung, AI und ML eingeschlossen, ins Leere. Leider erfolgen Zustandsrückmeldungen, wenn überhaupt, trotzdem meist nur nach Bauchgefühl und nicht quantitativ anhand von festgelegten physischen Zustandsmerkmalen.

### Was ist nun mit der Anwendung von IoT-Techniken?

Manch einer mag sich nun noch fragen, warum fast nichts über die Nutzung von ML, AI, etc. gesagt wurde. So attraktiv und interessant diese Technik auch sein mag, ihre Anwendung ist mit einigen Hürden verbunden.

ML und AI sind für das Aufspüren von P-F-Intervallen und Anomalien zwar nahezu unschlagbar, insbesondere wenn aus sehr vielen unstrukturierten Daten bisher unbekannte Ereignismuster und Zusammenhänge mit typischerweise Cloud-basierenden Mustererkennungs- oder Analytics-as-a-Service-Programmen aufgedeckt werden sollen. Je größer die Häufigkeit, umso automatischer kann das ML-Datenmodell erstellt werden. Umso mehr auch dann, wenn Daten über mehrere Anlagen oder gar Standorte hinweg ausgewertet werden können. Das Problem ist nicht die Technik, sondern die oft nicht vorhandenen Ausfalldaten und nachvollziehbaren Rückmeldungen zum Training des Modells. Da führt auch eine Umkehrung auf die Daten des Gutzustands nicht wirklich weiter.

Fehlende Ausfalldaten sind allerdings meist nicht die Folge ungenügender Dokumentation, sondern die gewünschte Folge der RCM-Strategie. Funktioniert die





RCM-Strategie, gibt es auch im schlimmsten Falle nur wenige sich wiederholende Ausfälle aus denselben Gründen.

Wie auch immer, hybride IT-Systeme, bei denen die bereits bekannten unvermeidbaren Anomalien zuerst in Echtzeit lokal in FOCOS aufgedeckt werden, halten wir für eine gute Lösung. In der Regel ist es nämlich sinnvoll, sich zuerst auf „die üblichen Verdächtigen“ zu konzentrieren und erst im zweiten Schritt mit einem Cloud-basierenden Analytics-as-a-Service-Programm eher seltene, unbekannte Zusammenhänge aufzudecken und deren kontinuierliche Überwachung dann als Regel wieder zurück auf den Edge-Computer zu verlagern.

## Fazit und Ausblick

Die vorausschauende Instandhaltung ist ein Schlüsselement der Industrie 4.0. Die Erwartungen sind entsprechend hoch. Die Betreiber von Thermoprozessanlagen erwarten, dass die Instandhaltungseffizienz insgesamt besser wird, sich die Zuverlässigkeit der Anlage erhöht und sich die Instandhaltungskosten verringern. Für Serviceanbieter bleiben diese Erwartungen nicht folgenlos. Nachhaltiger Erfolg wird nur noch möglich sein, wenn das vorhandene Serviceportfolio durch vorausschauende Instandhaltung ergänzt wird.

Ein Weg in eine vorausschauende Instandhaltung geht über Condition Monitoring, um sich anbahnende Zustandsverschlechterungen von ausfallkritischen Bauteilen rechtzeitig zu erkennen. Das in diesem Beitrag beschriebene CM-System umfasst Zustandserfassung, -monitoring, -überwachung, -diagnose, -prognose und es parametrisiert sich selbst. Es ist smart, weil alles zusammen wie ein Uhrwerk ineinandergreift.

Unser CM zur Anomalieerkennung hat seine Bewährungsprobe in der Praxis gut bestanden. Auch wenn wir nach bisher ca. neun Monaten Erprobungszeit keine Ausfälle vorhersehen konnten, weil es keine gab (vgl. unsere Ausführungen zur RCM-Strategie), sind wir von der Praxistauglichkeit voll überzeugt. Die Sensitivität versetzt uns immer wieder selbst in Erstaunen. In einigen Fällen konnten sogar ungenügend geschmierte Antriebssysteme identifiziert werden.

Der richtige Anwendungszeitpunkt ist jetzt! Ein Problem ist (noch), dass die gewonnenen Zustandsdaten oft unspezifisch sind und ein Abnutzungsproblem nur eingegrenzt werden kann. Dies ist für die Instandhaltung aber viel besser als nichts. Es ist auch gut möglich, dass aus den rasant zunehmenden Datenpools schon bald neue Informationen gewonnen werden können, die wir derzeit noch nicht sehen.

Skalierbarkeit und einfache Erweiterungsmöglichkeiten der Hard- und Software sind neben der unverzichtbaren Onlinefähigkeit eine wichtige Voraussetzung dafür, als Betreiber auch an zukünftigen Erkenntnissen und Weiterentwicklungen zu partizipieren. Es wird noch einige Updates und Verbesserungen geben<sup>4</sup>. Denn eines ist sicher: Anomalieerkennung als wichtiger Bestandteil einer vorausschauenden Instandhaltung steht noch am Anfang ihrer Erfolgsgeschichte.

## LITERATUR

- [1] Steck-Winter, H.; Stölting, C.; Unger, G.: Vorausschauende Instandhaltung mit datengetriebener Zustandsüberwachung – Teil 1. gwi – gaswärme international 66 (2017), Nr. 5, S. 87-95
- [2] Steck-Winter, H.; Stölting, C.; Unger, G.: Vorausschauende Instandhaltung mit datengetriebener Zustandsüberwachung – Teil 2. PROZESSWÄRME 1 (2018), Nr. 3, S. 49-58
- [3] Ahorner, M.: KI in der Fabrik – wie funktioniert das? Teil 1 bis 5, LinkedIn, 2020
- [4] Steck-Winter, H.: Vorausschauende Instandhaltung von Thermoprozessanlagen. gwi – gaswärme international 60 (2011), Nr. 3, S. 141-152
- [5] Defèr, F.: Predictive Maintenance Realitätscheck Teil 1 bis 3, Instandhaltung. verlag moderne industrie, 2020

## AUTOREN



**Dr. Hartmut Steck-Winter, MBA**  
Vormals Aichelin Service GmbH  
Ludwigsburg  
+49 (0)176 / 9787-3726  
steck-winter@gmx.de



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

<sup>4</sup> Damit ist aber ausdrücklich nicht das Bananenprinzip „grün ausliefern und beim Kunden reifen lassen“ gemeint.