

Computer-implementiertes Verfahren und System zur automatischen Überwachung und Statusermittlung ganzer Prozessabschnitte in einer Process Unit

Die Erfindung betrifft ein Verfahren und ein computer-implementiertes System zur automatischen
5 computer-implementierten Überwachung und Statusermittlung ganzer Prozessabschnitte in einer Process Unit.

Vor dem Hintergrund einer zunehmend heterogenen Systemlandschaft sowie des ständig
steigenden Automatisierungsgrades von Anlagen gewinnen innovative Assistenzsysteme und Plant
10 Asset Management (PAM) Lösungen für den Operator immer mehr an Bedeutung. Dabei kommt der Überwachung und Diagnose von Apparaten, Geräten und Automatisierungstechnik einer Process Units eine Schlüsselrolle zu.

Eine zentrale Zielsetzung des modernen Plant Asset Managements liegt in der Steigerung der
15 Anlagenverfügbarkeit und der Anlagenutzung durch Zustandsüberwachung von Feldgeräten und Anlagenkomponenten (Asset Monitoring).

Auf der Geräteebeane existieren in vielen Fällen bereits Asset-Statusinformationen. Beispielsweise
haben sich die sog. intelligenten Feldgeräte in vielen Betrieben schon weitgehend etabliert. Ebenso
20 werden auf der Ebene der komplexeren Maschinen und Apparate, wie etwa Pumpen oder Wärmetauschern, Condition Monitoring Systeme bereits angeboten und sind verfügbar [Mühlenkamp, S., Geipel-Kern, A.: Plant Asset Management: In der Diagnose mechanischer Assets schlummert ungenutztes Potenzial, PROCESS, (2011) Nr. 3, 36-38]. Aber auch hier ist die aufgabengerechte Verdichtung der Statusinformationen für den Anwender zwingend erforderlich.

Für die Überwachung und Diagnose bereits einfacher Apparatecluster und ganzer Teilanlagen
25 stehen zur Prozessführung bereits standardmäßig eine Vielzahl von Informationen, wie Mess- und Stellgrößen, zur Verfügung. Häufig haben die Anwender allerdings keine Möglichkeit, die Informationen in vollem Umfang zu nutzen. Um hier frühzeitig Hinweise über schleichende Verschlechterungsprozesse zu gewinnen, kommt einer automatisierten Verdichtung sowie deren
30 Abgleich mit dem aktuellen Betriebszustand zur echtzeitfähigen Bewertung der Asset Gesundheit eine Schlüsselrolle zu [Ross, T., Ochs, S., Frey, C.W.: Neue Software zur Überwachung „nicht intelligenter“ Anlagenteile – Teil 1, Chemie Technik, (2011) Ausgabe 11, S. 18-20.]. Denn erst auf der Basis derartiger, gesicherter Erkenntnisse ist eine Prognose und schließlich eine Ableitung geeigneter Maßnahmen möglich, etwa im Sinne der vorausschauenden Wartung, aber auch der
35 Produktions- bzw. Stillstandsplanung. Zuverlässige Asset-Statusinformationen bilden daher die Grundlage für vielfältige und unterschiedliche, für den Geschäftserfolg wesentliche Unternehmensentscheidungen.

Es bestand daher die Aufgabe, ein System und ein Verfahren zur Überwachung von prozesstechnisch zusammenhängenden Anlagenteilen (Process Units) zu entwickeln, welches sich ohne erhebliche Engineering- und Modellierungsaufwände auf Basis der bestehenden Feldinstrumentierung für die Asset Überwachung von Betrieben nutzen lässt, dem Anwender ein zuverlässiges sowie einfach und schnell zu bedienendes Überwachungswerkzeug darstellt, wobei die Asset-Statusinformationen pro Process Unit automatisch verdichtet und aggregiert in einfacher Form dargestellt ist. Es sollten Asset-Statusinformationen über die Ebene der intelligenten Feldgeräte hinaus, auch von „nicht intelligenten“ Anlagenteilen und von Teilanlagen verfahrenstechnischer Betriebe bereitgestellt werden. Hierfür bestand die Aufgabe darin, eine technische Softwarelösung bereitzustellen, die ermöglicht, dass die Schwellwertsetzung und damit die Unterscheidung zwischen Gutzustand und Abweichungen davon, automatisch während des Verfahrens ermittelt werden.

Im Sinne der Anmeldung sind intelligente Feldgeräte, die sich mittels Sensoren und / oder Diagnose-Software selber überwachen.

Die Überwachung von prozesstechnisch zusammenhängenden Anlagenteilen wurde durch ein computer-implementiertes Verfahren zur Überwachung von prozesstechnisch zusammenhängenden Anlagenteilen, die eine oder mehrere Prozess Units umfassen, gelöst, das folgende Schritte umfasst:

Im Schritt a) werden M zu überwachenden Prozessparameter, und deren Messbereichsgrenzen angelegt. Die Messbereichsgrenzen dienen zur Parametrierung des Modells (vergl. [Frey, C. W.: Prozessdiagnose und Monitoring feldbusbasierter Automatisierungsanlagen mittels selbstorganisierender Karten und Watershed-Transformation, at-Automatisierungstechnik 56 (2008) Nr. 7, S. 374-380]). Die Eingabe erfolgt üblicherweise über ein User Interface. Die Eingaben werden in einem Modul zur Definition der Prozess Unit gespeichert.

Im Schritt b) werden Lerndatenphasen bestehend aus potentiellen Lernvektoren in ein Datenbankmodul importiert. Die Lerndatenphasen werden üblicherweise aus einer Prozessdatenbank eines Prozessleitsystems importiert. Diese Lerndatenphasen bestehen aus potentiellen Lernvektoren jeweils definiert durch die Ist-, Soll-, und / oder Stellwerten für die M Prozessparameter aus Schritt a) und ein Zeitstempel t. Die Übertragung der Lerndatenphasen aus der Prozessdatenbank erfolgt über ein Daten-Interface (OPC, SQL); die importierten Lerndatenphasen werden in dem Datenbankmodul gespeichert. Das Datenbankmodul ist außerdem mit einem neuronalen Netz basierten Modellmodul verbunden.

Im Schritt c) werden in dem Datenbankmodul aus den Lerndatenphasen aus b) N Lernvektoren selektiert. Diese Selektion erfolgt typischerweise durch den Nutzer über den User Interface.

Im Schritt d) werden die selektierten Lernvektoren aus Schritt c) automatisch in das Modellmodul übertragen. Mit diesen Lernvektoren wird ein neuronales-Netz-basiertes Modell vollautomatisch mittels eines datengetriebenen Algorithmus erstellt. Hierfür wird jeder Lernvektor iterativ zu einem Neuron mit einem geringsten Abstand zum Lernvektor zugeordnet, bis die Neuronen eine selbstorganisierende Neuronenkarte (SOM) bilden (vergl. dazu http://en.wikipedia.org/wiki/Self-organizing_map, Frey, C. W.: Prozessdiagnose und Monitoring feldbusbasierter Automatisierungsanlagen mittels selbstorganisierender Karten und Watershed-Transformation, at-Automatisierungstechnik 56 (2008) Nr. 7, S. 374-380). Das so trainierte Modell bildet den Gutzustand (Referenz) der zu überwachenden Anlagenteilen ab.

Im Schritt e) werden folgende Merkmale des Modells automatisch berechnet (vergl. Fig. 7):

- Ein Abweichungsfehler als der Abstand jedes Prozessparameterwertes eines Lernvektors an den entsprechenden Prozessparameterwert der ihm zugeordneten Best Matching Unit (= Neuron mit dem geringsten Abstand),
- für jeden der N Lernvektoren ein Gesamtabweichungsfehler als die Summe der Abweichungsfehler seiner M Prozessparameter,

Im Ergebnis ergibt sich ein Residuum. Hierfür werden die Abweichungsfehler für alle M Prozessparameter jeder der N Lernvektoren berechnet, d.h. es werden anzahlmäßig $M \times N$ Abweichungen plus N Gesamtabweichungsfehler in einer Matrix berechnet.

Im Schritt f) werden die N Gesamtabweichungsfehler aus Schritt e) in ein Modul zur Analyse der Abweichungsfehler übertragen. In diesem Modul wird ein Minimal- und Maximalwert der N Gesamtabweichungsfehler automatisch berechnet. Der Minimal- bzw. Maximalwert der N Gesamtabweichungsfehler gibt eine zusammenfassende einfache Definition des Gutzustands anhand dessen die spätere Überwachung der Anlagen gewährleistet werden kann. Weiterhin vorteilhaft ist, dass der Gesamtabweichungsfehler berücksichtigt, dass ggf. nicht nur ein Prozessparameter allein sondern eine Kombination von Prozessparametern den tatsächlichen Gutzustand der Prozess Unit beschreiben. In einer bevorzugten Ausführungsform wird außerdem mindestens ein Schwellwert für den Gesamtabweichungsfehler automatisch berechnet und gesetzt. In dieser besonderen Ausführungsform umfasst das Verfahren folgende weitere Schritte für die automatische Setzung des Schwellwertes:

- der ermittelte Wertebereich der Gesamtabweichungsfehler dient als Basis für ein Histogramm der Gesamtabweichungsfehler. Er wird in 10 bis 100, bevorzugt 15 bis 75, besonders bevorzugt 50 äquidistante (Wertebereich-) Segmente unterteilt.
- Die Gesamtabweichungsfehler der Lernvektoren werden in die Segmente automatisch einsortiert. Eine Basisschwelle (vergl. Abb. 2) wird mit folgenden Schritten automatisch gesetzt: Basisschwelle = erste Segmentstützstelle, für die gilt, dass sich ≥ 5 bis 15%, bevorzugt $\geq 15\%$ der höchsten Gesamtabweichungsfehler innerhalb der Segmente ausgehend vom Maximalwert befinden (vergl. Abb. 2). Dabei gilt für die Basisschwelle die weitere Bedingung, dass die Basisschwelle sich im Bereich der obersten 7/10 der Segmente ausgehend vom Maximalwert befinden muss, d. h. bei einer Teilung in 50 Segmente im Bereich des 15.ten bis 50.ten Segmentes, und bei einer Teilung in 100 Segmente im Bereich des 30.ten bis 100.ten Segmentes,. Wenn sich die Basisschwelle außerhalb dieses Bereichs befinden sollte, gilt für das automatische Nachstellen der Basisschwelle der Prozentsatz $\geq 5\%$ statt $\geq 15\%$ der höchsten Gesamtabweichungsfehler.

Im Schritt g) erfolgt zur Überwachung der Prozess Units eine automatische Übertragung der online überwachten M Prozessparameterwerte (vergl. Fig. 7) zu einem Zeitpunkt t in das Datenbankmodul; diese bilden Überwachungsvektoren der Process-Unit über die Zeit. Die Überwachungsvektoren werden von dem Datenbankmodul in das Modellmodul weitergeleitet.

Im Schritt h) erfolgt in dem Modellmodul eine automatische Zuordnung jedes Überwachungsvektors aus Schritt g) zu seiner Best Matching Units der Neuronenkarte (SOM) aus Schritt c) durch Vergleich der Prozessparameterwerte des Überwachungsvektors mit den Prozessparameterwerten jedes Neurons der Neuronenkarte und Selektion eines Neurons auf Basis des geringsten Abstands,

Im Schritt i) eine automatische Berechnung der Abweichungsfehler jedes Prozessparameterwerts des Überwachungsvektors im Vergleich zu dem Prozessparameterwert der ihm zugeordneten Best Matching Unit und die Berechnung des Gesamtabweichungsfehlers des Überwachungsvektors. Diese Berechnung wird im Modul zur Analyse der Abweichungsfehler durchgeführt.

Im Schritt j) werden die Gesamtabweichungsfehler jedes Überwachungsvektors im Vergleich zum berechneten Minimal- und Maximalwert der Gesamtabweichungsfehler, bevorzugt im Vergleich zur Basisschwelle, besonders bevorzugt im Vergleich zur Basisschwelle multipliziert durch ein Toleranzbereich in Form eines ganzzahligen positiven Faktor von üblicherweise 2-4 erfahrungsgemäß vorzugsweise 3, über den User Interface angezeigt.

Zur Klarheit werden wesentliche Begriffe der Beschreibung folgendermaßen definiert:

- Eine Process Unit ist ein Anlagenteil oder ein prozesstechnisch zusammenhängender Prozessabschnitt, der mit der Erfindung auf Basis der bestehenden Sensorik/Aktorik, d.h. vom Prozessexperten selektierten Prozessparametern überwacht werden kann. In der erfindungsgemäßen Lösung können mehrere Process Units zur Überwachung definiert werden.
- Lerndatenphasen sind Phasen, die in Gänze oder abschnittsweise zum Trainieren des neuronalen-Netz-basierten Modells selektiert werden können und bestehen aus Zeitstempeln und entsprechend Lernvektoren der Dimension ($M \times 1$).
- Eine Überwachungsphase ist eine Phase, in der eine Prozess Unit überwacht wird und besteht aus einer Anzahl von Überwachungsvektoren.
- Die Prozessparameter wurden oder werden in einer Phase – Lernphase bzw. Überwachungsphase – zu diskreten Zeitpunkten (=Zeitstempel) abgetastet. Bei einer Abtastrate von 1/min, liegt nach der Überwachung pro Minute ein Vektor im Prozessdatenarchiv (=Prozessdatenbank) vor.
- Ein Lernvektor bzw. Überwachungsvektor – wird durch die Werte der im Schritt a) eingegebenen M Prozessparametern und einem Zeitstempel t definiert. Bei M Prozessparametern hat er die Dimension ($M \times 1$), d. h. M Parameterwerte. Die Werte der Prozessparameter sind üblicherweise die überwachten Ist-Werte der Process Units. Im Fall von Prozess-Regelungen können auch die Soll-Werte (auch Führungsgröße genannt) und / oder Stell-Werte (auch Stellgröße genannt) der Prozessparameter einbezogen werden. Auch eine Kombination dieser Werte zur Definition eines Lernvektors ist möglich. Typischerweise wird ein Überwachungsvektor durch seine M Ist-Werte bei einem Zeitstempel t definiert.
- Abweichungsfehler, auch Quantifizierungsfehler oder QFehler genannt, beschreiben den Anpassungsgrad des Modells an die Lernvektoren bzw. den Anpassungsgrad des Überwachungsvektors an das Modell. Der Abweichungsfehler ist das Abstandsmaß zwischen dem durch den Algorithmus berechneten Best Matching Unit (BMU) und dem präsentierten Lern- bzw. Überwachungsvektor. Für jeden Lernvektor bzw. Überwachungsvektor der Dimension ($M \times 1$) werden M Abweichungsfehler berechnet. Mit anderen Worten werden die Parameterwerte jedes Lernvektors mit den Parameterwerten der Best Matching Unit verglichen und der euklidische Abstand zwischen diesen Parametern berechnet.
- Der Gesamtabweichungsfehler, auch Gesamtquantifizierungsfehler, Gesamt-QFehler oder Gesamtfehler genannt, entspricht der Summe aller Abweichungsfehler eines Vektors.
- Das Residuum einer oder mehrerer Lerndatenphasen mit in der Summe N Zeitstempeln und Lernvektoren der Dimension ($M \times 1$) besteht aus der Matrix aus $M \times N$ Abweichungsfehlern. Das Residuum lässt sich als Qualitätsmerkmal für das Modell verwenden. Bei der vorliegenden Erfindung werden auch die N Gesamtabweichungsfehler in der Residuum Matrix aufgenommen.

- BMU, Best Matching Unit oder bestpassende Neuron: Wird dem neuronalen Netz ein Lern- bzw. Überwachungsvektor präsentiert, gibt es immer ein „Gewinnerneuron“ (z.B. euklidischen Abstand minimal), welches am besten mit dem präsentierten Vektor übereinstimmt, d. h. das Neuron mit dem geringsten Abweichungsfehler. Dieses heißt Best Matching Unit oder BMU und ist durch seine M Prozessparameterwerte definiert. Mit anderen Worten wird ein Modellvektor berechnet definiert durch seine M Parameter. Für die Berechnung der Best-Matching Unit einer selbstorganisierenden Neuronenkarte wird auf dem Stand der Technik verwiesen wie z. B. http://en.wikipedia.org/wiki/Self-organizing_map sowie auf Frey et al. [Frey, C. W.: Prozessdiagnose und Monitoring feldbusbasierter Automatisierungsanlagen mittels selbstorganisierender Karten und Watershed-Transformation, at-Automatisierungstechnik 56 (2008) Nr. 7, S. 374-380].

Wie die meisten neuronale Netze arbeiten die Neuronenkarte in zwei Phasen: Training (=Lernphase) und Zuordnung (=Mapping/Anwendungsphase). Das Training bildet die Neuronenkarte mit Hilfe von Lernvektoren, wobei Mapping die automatische Zuordnung eines neuen Vektors, z. B. ein Überwachungsvektor, ist. Diese Phasen sind auf Fig. 7 schematisch dargestellt.

Üblicherweise kann das Verfahren auf einem etwas leistungsfähigeren handelsüblichen Computer und durch eine auf diesem Computer installierte Software ausgeführt werden. Es werden keine besonderen Anforderungen an die Hardware gestellt. Die Erfindungsgemäße Lösung bedarf keine erhebliche Engineering- und Modellierungsaufwände und kann auf Basis der bestehenden Feldinstrumentierung zum Einsatz kommen.

Zur Anbindung des Computers inkl. Software an die Prozessüberwachung verfügt der Process Unit Monitor üblicherweise über OPC-, ODBC- und SQL-Schnittstellen. Im Fall der OPC-Schnittstelle werden die historischen Daten aus Schritt b) bzw. c) über OPC-HDA und Echtzeitdaten (=Überwachungsvektoren) aus Schritt g) über OPC-DA aus der Datenbank des Prozess-Leitsystems akquiriert. (Fig. 5)

Üblicherweise werden nach außen die Statusinformationen zusätzlich pro Process Unit mittels des internen OPC-DA Servers zu Verfügung gestellt.

Im Schritt a) sind als übliche zu überwachende zusammengehörige Anlagenteile (Process Units) bzw. Teilanlagen (Prozessabschnitte) definiert. Diese Anlagenteile oder Prozessabschnitte sind durch ihre zu überwachenden M Prozessparameter charakterisiert. Beispiele für Anlagenteile sind Destillationskolonne, Wärmetauscher-Pumpe Kombination, Trockner, Schneckenextruder oder Kessel samt angeschlossener Peripherie - wie Rohrleitungen und Instrumentierung. Hier legt der Prozessexperte die zur Überwachung notwendige Sensorik/Aktorik und die zugehörigen

Messbereiche fest. Er bestimmt, welche Prozessparameter - Drücke, Temperaturen, Durchflüsse, etc. - in die Überwachung einbezogen werden und welche nicht. Relevant sind üblicherweise alle Ist-, Soll- und /oder Stellwerte der betrachteten funktionalen Überwachungseinheit. Die Software unterstützt die Konfiguration, indem Prozessparameter einfach an und abgewählt werden können.

- 5 In einer besonderen Ausführungsform werden zusätzlich bestimmte Prozessparameter als „obligatorisch“ und / oder als „Schlüsselvariable“ deklariert.

Obligatorische Prozessparameter sind Prozessparameter, die für die Überwachung notwendig sind. Fällt ein obligatorischer Prozessparameter in der Überwachung aus, wird diese üblicherweise
10 automatisch deaktiviert und der Prozess Unit Status „Ampel“ wechselt von „rot“, „gelb“ oder „grün“ nach „grau“. Eine solche Änderung informiert den Nutzer über den Ausfall einer Sensorik/Aktorik in der Prozess Unit.

Schlüsselvariable sind obligatorische Parameter, die außerdem den zuvor definierten Wertebereich
15 nicht verlassen dürfen. Dazu wird vorzugsweise der Minimal und / oder der Maximal Wert einer jeden Lerndatenphase um einen einstellbar hohen Prozentsatz nach unten und oben als Toleranzbereich erweitert. Das Modell ist typischerweise nur in diesem zuvor definierten und erweiterten Wertebereich trainiert. Verlässt der Überwachungsvektor die so erweiterten Wertebereiche, wird die Überwachung der Prozess Unit samt Status Ampel ebenfalls deaktiviert
20 und „grau“. Im Fall einer Lastvariable (Feed) kann so verhindert werden, dass die Überwachung auf untrainierte Prozesszustände angewendet wird. Es gilt: Schlüsselvariable sind automatisch auch obligatorische Parameter. Umgekehrt ist das nicht der Fall.

In Schritt b) importiert der Anwender potenzielle Lerndatenphasen (Aquisdaten). Diese werden
25 zur nachfolgenden Begutachtung automatisch in der internen Datenbank (=Datenbankmodul) gespeichert.

Im Schritt c) kann der Prozessexperte die potenziellen Lerndatenphasen visualisieren und im Anschluss daraus Lern- bzw. Referenzdatensätze (ausgewählte Lerndatenphasen) selektieren , in
30 denen die Anlage den Anforderungen entsprechend dem Gutzustand gefahren wurde. Bevorzugt werden Lern- bzw. Referenzdatensätze für mehrere Produkte bzw. Lastzustände in das Modell eingegeben. Dazu wird in Schritt a) ein Last- bzw. Produktparameter einbezogen, der die verschiedenen Anlagenzustände (Produkt und / oder Lastzustände) markiert. Dieser wird üblicherweise als zusätzlicher „Prozessparameter“ mittrainiert. Mit anderen Worten können als
35 Prozessparameter nicht nur Daten über die Sensorik/Aktorik sondern bevorzugt auch Daten über Produkt und / oder Lastzustände benutzt werden. Dadurch reduzieren sich die Aufwände für die Modellerstellung und Überwachung.

Alternativ zum Import durch den Anwender und Selektion über das User Interface kann der Prozessexperte eine ausführliche Definition des Gutzustands im Schritt a) durchführen, die dann einen automatischen Import (Schritt b) und / oder Selektion (Schritt c) von Lerndatenphasen ermöglicht.

Im Schritt d) wird das neuronale Netz basierte Modell des Gutzustands berechnet. Das Training des neuronalen-Netz-basierten Modells erfolgt üblicherweise nach den Lernregeln von Frey et al. [Frey, C. W.: Prozessdiagnose und Monitoring feldbusbasierter Automatisierungsanlagen mittels selbstorganisierender Karten und Watershed-Transformation, at-Automatisierungstechnik (2008) Nr. 7, S. 374-380] dessen Inhalt per Referenz hier eingeführt wird. Der zu Grunde liegende Algorithmus basiert auf sog. selbstorganisierenden Karten (SOM) und die datengetriebene Modellerstellung nutzt Prozessinformationen (aus der angeschlossenen Aktorik / Sensorik), wie z.B. Temperaturen, Durchflüsse, Drücke, Motorströme, etc, aus zu überwachenden Anlagenteils bzw. der zu überwachenden Teilanlage. Der mathematische Kernalgorithmus für das Überwachen von Anlagenteilen wurde zuvor bereits erfolgreich im Rahmen eines Diagnosekonzepts für feldbusbasierte Automatisierungsanlagen eingesetzt [Ross, T., Hedler, C. , S., Frey, C.W: Neue Softwarewerkzeug zur Überwachung „nicht intelligenter“ Anlagenteile und Teilanlagen In: AUTOMATION 2012 13. Branchen- treff der Mess-und Automatisierungstechnik. VDI-Berichte 2171. Baden-Baden, 2012, S. 231 – 235, ISBN 978-3-18-092171-6].

Dank der Anwendung eines neuronalen Netzes konnte das Werkzeug derart konzipiert werden, dass sich der Anwender die Überwachungsmodelle eigenhändig – sozusagen per Knopfdruck - innerhalb einer Minute erzeugen kann und sie im Anschluss sofort für die Überwachung verwenden kann. Dazu wählt sich der Prozessexperte die notwendigen Prozessinformationen in Form von sog. Lern- oder auch Referenzdatensätzen aus. Dieser datengetriebene Ansatz unterscheidet sich grundlegend von der Vorgehensweise bei analytisch modellbasierten Methoden. Diese erfordern eine aufwändige Modellierung und viel Erfahrung vonseiten der Entwickler. Ändert sich der Prozess, z. B. weil bauliche oder prozessoptimierende Maßnahmen durchgeführt wurden, muss auch das analytische Modell entsprechend angepasst werden. Zusätzliche Modellierungsaufwände sind die Folge. Dagegen bedarf es bei dem hier vorgestellten datengetriebenen Ansatz lediglich einer neuerlichen Anpassung des Modells durch den Anwender. Das neuronale-Netz-basierte Modell ist durch Training anpassungsfähig bei Änderung des Inputs.

Zusammenfassend bildet das trainierte Modell den Gutzustand (Referenz) des zu überwachenden Prozessabschnittes ab. Abweichungen zum Modell werden flexibel und in einer bevorzugten Ausführungsform der Erfindung automatisch in Schwellwerten, mindestens in einer Basisschwelle

besonders bevorzugt multipliziert durch den Toleranzbereich in Form eines ganzzahligen positiven Faktor von üblicherweise 2-4 erfahrungsgemäß vorzugsweise 3 übersetzt.

Bei der Berechnung der Basisschwelle wird die Anzahl der Segmente auf Basis von Erfahrungswerten gesetzt und beträgt üblicherweise von 10 bis 100, bevorzugt 15 bis 75, besonders bevorzugt 50. Die Auflösung des Wertebereiches muss hoch genug sein um die Schwelle präzise setzen zu können. Dies ist bei mindestens 50 Segmenten gegeben. Bei der Definition der Anzahl der Segmente soll der Nutzer aber achtgeben, dass die Auflösung nicht zu hoch wird- also dem Problem angepasst bleibt. Sonst kann es zu zahlreichen unbesetzten Segmenten kommen, was zu unnötig hohem Rechenaufwand führt. Bei der Einsortierung der Lernvektoren anhand deren Gesamtabweichungsfehler in die Segmente kann in seltenen Fällen vorkommen, dass sich mehr als 85% der Ereignisse im 1.ten bis zum 15.ten Segment befinden und der Rest auf die Segmente 16-50 verteilt. In diesem Fall würde der %-Satz von $\geq 15\%$ der Lerndatenvektoren mit dem Gesamtabweichungsfehler $\geq$ Basisschwelle zu tief gesetzt. Daher wird der %-Satz der Lerndatenvektoren mit dem Gesamtabweichungsfehler $\geq$ Basisschwelle üblicherweise nach $\geq 5\%$ der Ereignisse mit den höchsten Werten gesetzt. Besonders bevorzugt wird die berechnete Basisschwelle durch einen Toleranzbereich in Form eines ganzzahligen positiven Faktor von üblicherweise 2-4 erfahrungsgemäß vorzugsweise 3 multipliziert.

Optional können auch die Abweichungsfehler in das Modul zur Analyse der Abweichungsfehler übertragen werden und eine Basisschwelle für jeden Prozessparameter ermittelt werden. Ein weiteres Output des Verfahrens ist dann eine Zuordnung des betrachteten Parameters jedes Überwachungsvektors im Vergleich zu einer vorparametrierten Schwelle (Basisschwelle mal der positiver ganzzahliger Faktor) des betrachteten Parameters.

Wird das System für die Überwachung einer Prozess Unit über längere Zeit eingesetzt, wächst die Anzahl von anwendbaren Lerndatensätzen. Es ist ggf. vorteilhaft, das Training des neuronalen Netzes zu wiederholen, um neue Lernsätze im Modell des Gutzustands zu berücksichtigen. Die Modellaktualisierung sollte idealerweise als Teil einer gelebten PAM-Strategie in den betrieblichen Alltag integriert werden. Die Aufwände sind Dank der einfachen Bedienung und der geringen Anzahl an Arbeitsschritten überschaubar. Und auch für die Aktualisierung eines Modells braucht es in der Regel nur wenige Minuten.

Für eine bessere Bedienbarkeit wird der Output bevorzugt in Form eines Ampelsystems wie auf Fig. 3 dargestellt. Für die Rotschwelle wird üblicherweise die ermittelte Basisschwelle standardmäßig mit dem zusätzlichen positiver ganzzahliger Faktor als Einstellparameter (Wert = 3) multipliziert und die Gelbschwelle standardmäßig aber einstellbar auf 75% der Höhe der

Rotschwelle gesetzt. Der Einstellparameter steuert die Empfindlichkeit der Fehlererkennung (also ob bereits kleine oder erst große Abweichungen vom trainierten Modell zu einer roten Ampel führen) im Zuge der anschließenden Überwachung des Anlagenteils bzw. der Teilanlage und kann optional geändert werden. Ebenso ist die Gelbschwelle als prozentualer Anteil der Rotschwelle optional änderbar.

Gemäß dem Ampelschema (grün= OK, gelb= Achtung, rot = Fehler) werden die Gelb- und eine Rotschwelle gesetzt, die es im Fall der Überwachung (Echtzeit) bzw. der Analyse (Offline) erlaubt, den Anwender über den Gesundheitszustand (Asset-Status) des Anlagenteils bzw. der Teilanlage zu informieren (vergl. Abb. 1).

Die Platzierung der Ampeln zur Visualisierung des Process Unit Status ausgehend aus der berechneten Basisschwelle kann vorzugsweise vom Nutzer über das User Interface angepasst werden. Auf Bedienbildern wird typischerweise für jede Process Unit eine Ampel (OK, Erhöhte Aufmerksamkeit, Fehler) auf dem zugehörigen Bedienbild visualisiert. Später können mögliche Abweichungen auf diese Weise in Echtzeit von den Anlagenfahrern registriert werden. Bei „Gelb“ oder „Rot“ ist der Prozessexperte zwecks Detailanalyse zu informieren.

Zur besseren Übersicht der abweichenden Prozessparameter können die Prozessparameterabweichungen von einem üblicherweise von mehreren Überwachungsvektoren, absteigend nach Größe (z. B. in Form eines Top 10) graphisch zugeordnet dargestellt werden (Fig 6).

Zusätzlich kann für jeden Prozessparameter sein prozentualer Anteil am Gesamtabweichungsfehler berechnet und graphisch dargestellt werden.

Weiterer Gegenstand der Anmeldung ist eine Computerprogramm bzw. eine Software zur Durchführung des computer-implementiertes Verfahrens.

Weiterer Gegenstand der Erfindung ist ein Computersystem zur Überwachung von prozesstechnisch zusammenhängenden Anlagenteilen, welche einer oder mehreren Prozess Units umfassen, umfassend folgende Module:

- a) Ein User Interface zur Definition i) von zu überwachenden M Prozessparametern und ii) Input der Messbereichsgrenzen der M Prozessparameter einer oder mehreren zu überwachenden Process Units,
- b) Ein Modul zur Definition der Prozess Unit zur Speicherung des Inputs i) und ii), verbunden mit dem User Interface,
- c) ein Datenbankmodul zum Import und zur Speicherung von Lerndatenphasen, Lernvektoren und Überwachungsvektoren über ein Daten-Interface, wobei das Datenbankmodul mit dem Modul zur Definition der Prozess Unit und mit dem User Interface verbunden ist,

d) ein neuronal-Netz-basiertes Modellmodul zum vollautomatischen Trainieren eines neuronalen-Netz-basierten Modells durch automatische Berechnung von:

- Best-Matching Units und einer selbstorganisierenden Neuronenkarte der Best-Matching-Units,
- Ein Abweichungsfehler als der Abstand jedes Prozessparameterwertes eines Lernvektors an das entsprechende Prozessparameterwert des ihm zugeordneten Best Matching Units,
- für jeden der N Lernvektoren ein Gesamtabweichungsfehler als die Summe der Abweichungsfehler seiner M Prozessparameter,

sowie zur Zuordnung eines Überwachungsvektors zu einer der Best-Matching Unit der selbstorganisierenden Neuronenkarte und Berechnung von:

- Einem Abweichungsfehler als der Abstand jedes Prozessparameterwertes des Überwachungsvektors an das entsprechende Prozessparameterwert des ihm zugeordneten Best Matching Units,
- für jeden der Überwachungsvektoren einem Gesamtabweichungsfehler als die Summe der Abweichungsfehler seiner M Prozessparameter,

e) ein Modul zur Analyse der Abweichungsfehler durch automatische Ermittlung eines Bereichs der berechneten Gesamtabweichungsfehler, Einsortierung der Lern- und Überwachungsvektoren anhand deren Gesamtabweichungsfehler in dem ermittelten Bereich, wobei das Modul zur Analyse der Abweichungsfehler mit dem Modellmodul verbunden ist, und

wobei das Modul zur Analyse der Abweichungsfehler mit dem User Interface für die Darstellung der Einsortierung der Überwachungsvektoren im Bereich der berechneten Gesamtabweichungsfehler verbunden ist.

Das erfindungsgemäße Systems ist besonders vorteilhaft für alle nicht standardmäßig mit einer Eigendiagnose ausgerüsteten Anlagenkomponente, wie etwa Kesseln und Rohrleitungen, Wärmetauschern oder Destillationskolonnen [Hotop, R., Ochs, S., Ross, T.: Überwachung von Anlagenteilen, atp edition, 06/2010]. Der Grundintention des erfindungsgemäßen Systems folgend, werden die Prozessparameter einer Process Unit nicht für sich allein, isoliert, betrachtet. Vielmehr korreliert das System alle Parametersätze miteinander und erfasst auf diese Weise das charakteristische Zusammenspiel der einzelnen Komponenten der zu überwachenden funktionalen Einheit. Es erlernt und überprüft dabei deren Abhängigkeiten und leitet daraus summarische Statusaussagen ab, etwa im Sinne eines Ampelschemas, bei dem zwischen Gutzustand („grün“), sich abzeichnendem Handlungsbedarf („gelb“) und Fehlfunktion („rot“) unterschieden wird.

Zudem hat sich gezeigt, dass der Process Unit Monitor auch gewinnbringend zur Überwachung von störungsanfälligen Asset-Kombinationen eingesetzt werden kann, für die prinzipiell auch bereits Einzelüberwachungslösungen auf dem Markt existieren. Zum einen um bestimmte Typen von Anlagenproblemen abzudecken, die bisher nicht erfasst wurden oder auch zum anderen, um kausale Wirkzusammenhänge in den Verschlechterungsprozessen aufzudecken, beispielsweise wenn sich Anlagenprobleme innerhalb einer Teilanlage von Asset zu Asset fortpflanzen.

Auf der anderen Seite verdeutlicht Bild 1, dass Process Unit Monitoring richtig verstanden bereits einige Elemente klassischer Prozessführung (Performance Monitoring) enthält. Allerdings nicht im Sinne einer Prozessführung nach Key Performance Indikatoren, um einen optimaleren Fahrzustand zu finden. Sondern eher im Sinne einer gezielten Überwachung von bestimmten Teilprozessen, um Informationen über nachlassende Asset Performance abzuleiten, die nicht unmittelbar auf eine Beeinträchtigung der Asset-Gesundheit zurückzuführen ist. Etwa durch Verlassen der optimalen Fahrweise der Anlage.

Fig 1 zeigt eine schematische Darstellung des Plant Asset Management (PAM), wobei Process Unit Monitoring mit Condition und Performance Monitoring kombiniert wird.

Fig. 2 zeigt ein Histogramm der Gesamtabweichungsfehler als Ereignishäufigkeit pro Wertebereichssegment.

Fig. 3 zeigt Schwellwerte zur Überwachung und Analyse des Asset Status.

Fig. 4 zeigt eine schematische Darstellung der Architektur des erfindungsgemäßen Systems mit Schnittstellen.

Fig 5 zeigt eine schematische Darstellung der Systemintegration in die Anlagelandschaft.

Fig. 6 zeigt eine graphische Darstellung von nach Größe zugeordneten Parameterabweichungen (Top-10 Darstellung, wobei zur Übersicht lediglich die ersten 3 Parameter angezeigt werden).

Fig. 7 zeigt eine schematische Darstellung der Training und Zuordnungsphase.

Ansprüche:

1. Computer-implementiertes Verfahren zur Überwachung von prozesstechnisch zusammenhängenden Anlagenteilen, die eine oder mehrere Prozess Units umfassen, mit folgenden Schritten:

Im Schritt a) werden zu überwachenden M Prozessparameter, und deren Messbereichsgrenzen in einem User Interface eingegeben, und an ein Modul zur Definition der Prozess Unit weitergeleitet,

Im Schritt b) werden Lerndatenphasen bestehend aus potentiellen Lernvektoren in ein Datenbankmodul importiert,

Im Schritt c) werden in dem Datenbankmodul N Lernvektoren aus den Lernphasen aus b) über das User Interface alternativ automatisch anhand der Messbereichsgrenzen aus Schritt a) selektiert,

Im Schritt d) werden die Lernvektoren aus Schritt c) aus dem Datenbankmodul in ein damit verbundenes Modellmodul übertragen; im Modellmodul wird ein neuronales-Netz-basiertes Modell dadurch erzeugt, dass jeder Lernvektor zu einer Best Matching Unit definiert durch ihre M Prozessparameter zugeordnet wird und die Best Matching Units den Lernvektoren in einer selbstorganisierende Neuronenkarte angepasst werden,

Im Schritt e) werden folgende Merkmale des Modells automatisch berechnet:

- für jeden der N Lernvektoren ein Abweichungsfehler als der Abstand jedes Prozessparameterwertes eines Lernvektors an den entsprechenden Prozessparameterwert der ihm zugeordneten Best Matching Unit,
- für jeden der N Lernvektoren ein Gesamtabweichungsfehler als die Summe der Abweichungsfehler seiner M Prozessparameter,

Im Schritt f) wird der Gesamtabweichungsfehler pro Lernvektor aus Schritt e) in einem Modul zur Analyse der Abweichungsfehler übertragen und dort ein Minimal- und Maximalwert der berechneten N Gesamtabweichungsfehler automatisch ermittelt,

Zur Überwachung der Prozess Units erfolgt im Schritt g) eine automatische Übertragung der online überwachten M Prozessparameter zu einem Zeitstempel t als Überwachungsvektor der Prozess-Unit über die Zeit in das Datenbankmodul, gefolgt durch die Übertragung des Überwachungsvektors in das Modellmodul,

Im Schritt h) erfolgt in dem Modellmodul eine automatische Zuordnung jedes Überwachungsvektors aus Schritt g) zu den Best Matching Units der Neuronenkarte (SOM) aus Schritt c) durch Vergleich der Prozessparameterwerte des Überwachungsvektors mit den Prozessparameterwerten jedes Neurons der Neuronenkarte und Selektion auf Basis des geringsten Abstands,

Im Schritt i) erfolgt die Berechnung der Abweichungsfehler und der Gesamtabweichungsfehler des Überwachungsvektors,

Im Schritt j) wird der Gesamtabweichungsfehler der Überwachungsvektoren in das Modul zur Analyse der Abweichungsfehler übertragen, im Vergleich zum Minimal- und Maximalwert der berechneten N Gesamtabweichungsfehler aus f) zugeordnet und die Zuordnung wird über das User Interface angezeigt.

2. Computer-implementiertes Verfahren gemäß Anspruch 1, wobei der im Schritt f) durch den Minimal- und Maximalwerte ermittelte Wertebereich in von 10 bis 100 äquidistante Segmente unterteilt wird, die Lernvektoren anhand deren Gesamtabweichungsfehler in die Segmente einsortiert werden, und mindestens eine Schwelle automatisch mit folgenden Schritten gesetzt wird, Schwelle = erste Segmentstützstelle, für die gilt, dass sich ≥ 5 bis 15%, der höchsten Gesamtabweichungsfehler innerhalb der Segmente ausgehend vom Maximalwert befinden und die Schwelle sich im Bereich der obersten 7/10 der Segmente ausgehend vom Maximalwert befindet.

3. Computer-implementiertes Verfahren gemäß Anspruch 2, wobei die berechnete Schwelle durch ein Toleranzbereich in Form eines ganzzahligen positiven Faktors von üblicherweise 2-4 multipliziert wird.

4. Computerprogramm bzw. eine Software zur Durchführung des computer-implementierten Verfahrens nach einem der Ansprüche 1 bis 3.

5. Software zur Durchführung des computer-implementiertes Verfahrens nach einem der Ansprüche 1 bis 3.

6. Computersystem zur Überwachung von prozesstechnisch zusammenhängenden Anlagenteilen umfassen eine oder mehreren Prozess Units, wobei das Computersystem folgenden Modulen umfasst:

a) Ein User Interface zur Definition i) von zu überwachenden M Prozessparametern und ii) Input der Messbereichsgrenzen der M Prozessparameter einer oder mehreren zu überwachenden Process Units,

b) Ein Modul zur Definition der Prozess Unit zur Speicherung des Inputs i) und ii), verbunden mit dem User Interface,

c) ein Datenbankmodul zum Import und zur Speicherung von Lerndatenphasen, Lernvektoren und Überwachungsvektoren über ein Daten-Interface, wobei das Datenbankmodul mit dem Modul zur Definition der Prozess Unit und mit dem User Interface verbunden ist,

d) ein neuronales-Netz-basiertes Modellmodul zum vollautomatischen Trainieren eines neuronalen-Netz-basierten Modells in einer selbstorganisierende Neuronenkarte durch automatische Berechnung von:

- Ein Abweichungsfehler als der Abstand jedes Prozessparameterwertes eines Lernvektors an das entsprechende Prozessparameterwert des ihm zugeordneten Best Matching Units,
- für jeden der N Lernvektoren ein Gesamtabweichungsfehler als die Summe der Abweichungsfehler seiner M Prozessparameter,

sowie zur Zuordnung eines Überwachungsvektors zu einer der Best-Matching Unit der selbstorganisierenden Neuronenkarte und Berechnung von:

- Ein Abweichungsfehler als der Abstand jedes Prozessparameterwertes des Überwachungsvektors an den entsprechenden Prozessparameterwert der ihm zugeordneten Best Matching Unit,
- für jeden der Überwachungsvektoren ein Gesamtabweichungsfehler als die Summe der Abweichungsfehler seiner M Prozessparameter,

e) ein Modul zur Analyse der Abweichungsfehler durch automatische Ermittlung eines Bereichs der berechneten Gesamtabweichungsfehler, Einsortierung der Lern- und Überwachungsvektoren anhand deren Gesamtabweichungsfehler in dem Bereich, wobei das Modul zur Analyse der Abweichungsfehler mit dem Modellmodul verbunden ist, und wobei das Modul zur Analyse der Abweichungsfehler mit dem User Interface für die Darstellung der Einsortierung der Überwachungsvektoren im Bereich der berechneten Gesamtabweichungsfehler verbunden ist.

7. Computersystem nach Anspruch 4, wobei Modul zur Analyse der Abweichungsfehler, den ermittelten Bereich in Segmente teilen kann, die Lern- und Überwachungsvektoren in den Bereichssegmenten einsortieren kann und eine Schwelle automatisch auf Basis der Verteilung der Lernvektoren in den Segmenten ermitteln kann.