

Zustandsüberwachung und Performanzprognose

Datenbasierte Verfahren für komplexe Industrieanlagen

Für die Prozessüberwachung und Fehlerdiagnose gibt es bereits viele datenbasierte Verfahren. Im Gegensatz zu modellbasierten Verfahren bietet der datenbasierte Ansatz die Möglichkeit, ein statistisches Modell aus historischen Daten zu ermitteln, um anspruchsvolle und hochkomplexe Industrieanlagen zu überwachen. Verfahren zur Performanzprognose von Industrieanlagen führen die Gedanken der datenbasierten Zustandsüberwachung konsequent weiter und eröffnen neue Möglichkeiten, fehlertolerante Systeme und Anlagen zu entwickeln. Es wurden unterschiedliche Industrieprozesse mittels datenbasierter Verfahren unter der Zielstellung der Fehlererkennung und -lokalisierung sowie der Performanzprognose analysiert. Die Leistungsfähigkeit datenbasierter Verfahren wird anhand von Messdaten von Windkraftanlagen und einer Industrieanlage dargestellt.

SCHLAGWÖRTER Fehlererkennung / Hauptkomponentenanalyse /
Reconstruction-based Contribution / Performanzprognose /
Singular Spectrum Analysis

Condition monitoring and performance prognosis – Subheadline Essay englisch

A large number of data-driven techniques have been developed and applied for the purpose of industrial process monitoring and fault diagnosis. In contrast to model-based methods, data-driven approaches provide possibilities of efficient process monitoring for sophisticated and highly complex modern industry machines, by extracting statistical models based only on historical process data. Different technical systems are investigated in this project, such as an industrial process and wind energy conversion system, where data-driven methods have been studied with real process data for fault detection, fault identification and performance prognosis. In the rest of this paper, the performance of studied data-driven methods in above mentioned topics will be addressed with two example of an industrial process and wind energy conversion system.

KEYWORDS diagnosis / principal component analysis / reconstruction-based
contribution / performance prognosis / singular spectrum analysis

MINJIA KRÜGER, Universität Duisburg-Essen
TORSTEN JEINSCH, Universität Rostock
PETER ENGEL, PC-Soft
STEVEN X. DING, Universität Duisburg-Essen
ADEL HAGHANI, Universität Rostock

Die führenden Industrienationen unternehmen große Anstrengungen, um die Sicherheit, Verfügbarkeit und Leistung von komplexen technischen Systemen und Anlagen stetig zu erhöhen. Dieser Prozess fußt auf der frühzeitigen Erkennung von Fehlern, Ausfällen und steigenden Risiken, um mit Hilfe der Prozessführung zielgerichtete Maßnahmen einzuleiten, wie zum Beispiel Wartungs- und Instandhaltungsarbeiten zur Vermeidung und Reduzierung von Anlagenstillstandszeiten.

Klassische post-mortem-Strategien und der Einsatz zusätzlicher Sensorhardware können die notwendige Qualität einer frühzeitigen Erkennung selten gewährleisten. Moderne modellbasierte Verfahren auf der Basis einer physikalischen Systemmodellierung sind oft für komplexe industrielle Prozesse sehr schwierig und unrentabel zu handhaben. Diesen Anforderungen wird aktuell mit Hilfe von datengestützten multivariaten Verfahren begegnet. Hierbei wird in einer Offlinetrainingsphase der nominale und fehlerfreie Betriebszustand aus historischen Daten extrahiert und durch ein statistisches Modell abgebildet. Im Onlinebetrieb werden die gemessenen Daten mit dem nominalen und fehlerfreien Systemzustand, vorliegend als statistisches Modell, verglichen und ausgewertet.

In der Anlagenindustrie und bei komplexen industriellen Prozessen genießen datengestützte Methoden zur Überwachung und Fehlerdiagnose eine hohe Akzeptanz [9]. Diese fußt auf folgenden Punkten:

- Für datengestützte Ansätze sind keine physikalischen Modelle erforderlich.
- In einer Offlinetrainingsphase wird der nominale und fehlerfreie Betriebszustand aus historischen Daten extrahiert und durch ein statistisches Modell abgebildet. Bei Prozessveränderungen kann durch wiederholtes Offlinetraining eine Adaption an das geänderte Prozessverhalten vorgenommen sowie an verschiedene industrielle Prozesse angepasst werden.
- Im Gegensatz zur verbreiteten univariaten Methode wird bei den datengestützten multivariaten Me-

thoden die Korrelation zwischen den Betriebsmessdaten berücksichtigt.

- Diese datengestützten Verfahren eignen sich für den Umgang mit hochdimensionalen Datenmengen. Da oft wenige Komponenten der Messdaten relevant für die Überwachung und Fehlerdiagnose sind, werden Verfahren herangezogen, um die Datenmenge nach ihrer Bedeutung beziehungsweise nach der Abweichung der Menge in dieser Dimension zu klassifizieren [9]. Die so ausgewählten Daten bilden alle relevanten Prozesscharakteristiken mit einer deutlich reduzierten Datendimension ab und verlangen in der Onlinemonitoringphase weniger Berechnungsressourcen.

Aufgrund dieser Argumente sind datengestützte multivariate Verfahren eine kosteneffektive Alternative für die industrielle Prozessüberwachung und Fehlerdiagnose.

Eine intensive Untersuchung von datengestützten multivariaten Verfahren erfolgte bislang mit dem Fokus der Leistungsverbesserung zur Fehlererkennung und Identifikation (fault detection and isolation, FDI) [2]. Neben den betrachteten Fehlfunktionen ist jedoch die Performanzverschlechterung ein weiterer entscheidender Aspekt, der den Verlust von Kapazität und Verfügbarkeit einer industriellen Anlage bestimmt. Mit einem übergeordneten Performanz-Monitoring und einer effektiven Bestimmung der Restlebensdauer (remaining useful life, RUL) von Schlüsselkomponenten lassen sich effiziente Instandhaltungsmaßnahmen vorschlagen und rechtzeitig im Voraus durchführen.

Daher widmet sich dieser Beitrag datengestützten multivariaten Ansätzen zur Überwachung und Performanzprognose von komplexen industriellen Anlagen. Bild 1 zeigt eine vereinfachte schematische Darstellung des vorgeschlagenen Ansatzes. Er enthält 5 grundlegende Schritte: Prozessüberwachung, Erkennung und Lokalisierung der Degradation, Merkmalextraktion, Merkmalprognose und Lebensdauer-schätzung.

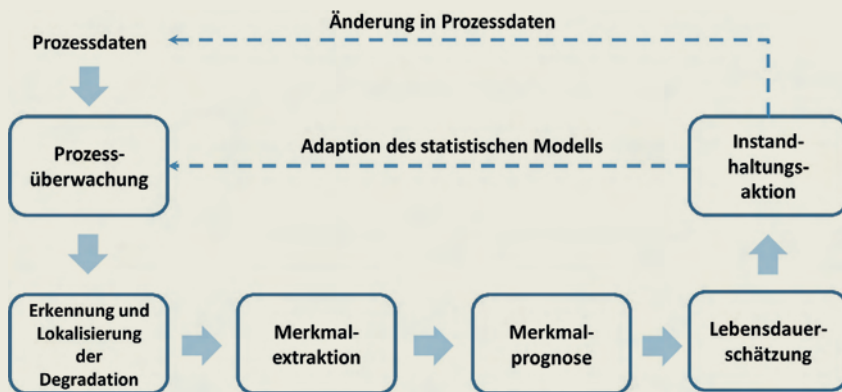


BILD 1: Schematische Darstellung der datengestützten Überwachung und Performanzprognose [7, 8]




BILD 2: Grundlegende Signalzusammensetzung [8]

1. METHODEN

Die entwickelten und eingesetzten Methoden werden in den folgenden Abschnitten näher vorgestellt. Ausführliche Information und die analytischen Grundlagen sind der angeführten Literatur zu entnehmen [1, 3, 4, 6, 9].

1.1 Prozessüberwachung

Für die Prozessüberwachung gibt es viele datenbasierte Verfahren. Sie eignen sich auch für den Umgang mit hochdimensionalen Daten. Hierbei werden die Daten unter Beibehaltung der Prozesscharakteristiken in einen niederdimensionalen Raum projiziert [2]. Im Beitrag wird das Standard-Hauptkomponentenanalyseverfahren (principal component analysis, PCA) zum Zweck der Prozessüberwachung eingesetzt. Die Anzahl der berücksichtigten Messstellen ist m .

Nachfolgend sind die wesentlichen Schritte des Offlinetrainingsprozesses zum Standard-PCA-Verfahren aufgeführt:

- **Datenerfassung und Normierung:** Für jede der m Messstellen erfolgt die Verarbeitung von N Datensätzen des Normalbetriebs und die Zusammenfassung zur Originaldatenmatrix $X \in R^{N \times m}$. Der Mittelwert μ und die Standardabweichung σ jeder Messstelle werden berechnet und im System gespeichert. Die Normierung der Originaldatenmatrix X verfolgt das Ziel, die resultierende Matrix Z mit dem Mittelwert $\bar{Z} = 0$ und der Standardabweichung $Z_\sigma = 1$ zu bestimmen. Als Ergebnis der Normierung entsteht die Datenmatrix $Z^T = [z_1 \dots z_N] \in R^{m \times N}$.
- **Berechnung der Eigenwerte und Eigenvektoren:** Zuerst wird die Kovarianzmatrix gebildet. Die Eigenwerte und -vektoren werden mit Hilfe der Eigenwertzerlegung bestimmt:

$$\Sigma \approx \frac{1}{N-1} Z^T Z = P \Lambda P^T, \quad (1)$$

wobei $\Lambda = (\lambda_1, \dots, \lambda_m)$ eine Diagonalmatrix ist, die die Eigenwerte in absteigender Größe enthält ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m \geq 0$). In der orthogonalen Ma-

trix P sind die Eigenvektoren zu den geordneten Eigenwerten $(\lambda_1, \dots, \lambda_m)$ von Σ enthalten. l beschreibt die Anzahl der Hauptkomponenten, die sich mit Hilfe des in [5] vorgeschlagenen Kriteriums ermitteln lassen. Damit erfolgt die Aufteilung des m -dimensionalen Raums von P und Λ in zwei Unterräume (Unterraum der Hauptkomponenten P_{pc} und Unterraum der Residuen P_{res}):

$$\Lambda = \begin{bmatrix} \Lambda_{pc} & 0 \\ 0 & \Lambda_{res} \end{bmatrix}, \quad P = [P_{pc} \quad P_{res}], \quad (2)$$

$$\Lambda_{pc} = \text{diag}(\lambda_1, \dots, \lambda_l) \in R^{l \times l} \quad (3)$$

$$\Lambda_{res} = \text{diag}(\lambda_{l+1}, \dots, \lambda_m) \in R^{(m-l) \times (m-l)} \quad (4)$$

$$P_{pc} \in R^{m \times l}, \quad P_{res} \in R^{m \times (m-l)} \quad (5)$$

Bestimmung der Schwellwerte: Für die Prozessüberwachung können grundsätzlich zwei Kennwerte angewendet werden, Squared Prediction Error (SPE) sowie die Hotelling T^2 -Verteilung. Mit dem gegebenen Signifikanzniveau α werden die entsprechenden Schwellwerte mit folgenden Formeln berechnet:

$$J_{th,SPE} = \theta_1 \left[\frac{h_0 c_\alpha \sqrt{2\theta_2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{\frac{1}{h_0}} \quad (6)$$

$$J_{th,T^2} = \frac{l(N^2 - 1)}{N(N - l)} F_\alpha(l, N - l), \quad (7)$$

wobei c_α die normierte Abweichung entsprechend des oberen $(1 - \alpha)$ Perzentils darstellt und

$$\theta_i = \sum_{j=i+1}^m (\lambda_j)^i, \quad i = 1, 2, 3, \quad h_0 = 1 - \frac{2\theta_1\theta_3}{3\theta_2^2} \quad (8)$$

gilt.

Die Onlineüberwachung und -diagnose setzt sich aus den folgenden Schritten zusammen:

Fehlererkennung

- Datennormierung: Mit Mittelwert μ und Standardabweichung σ vom Offlinetraining erfolgt die Normierung des neuen Onlineprozessdatensatzes.
- Ermittlung der Indizes: Für einen normierten Datenvektor $z \in R^m$, können die entsprechenden Indizes zu SPE und Hotellings T^2 mit den folgenden Gleichungen berechnet werden:

$$SPE = z^T P_{res} P_{res}^T z \quad (9)$$

$$T^2 = z^T P_{pc} \Lambda_{pc}^{-1} P_{pc}^T z. \quad (10)$$

- Fehlererkennungslogik: $SPE \leq J_{th,SPE}$ und $T^2 \leq J_{th,T^2} \Rightarrow$ fehlerfrei, ansonsten fehlerbehaftet.

Fehlerlokalisierung

Sollte eine Abweichung vom Normalzustand bei der Prozessüberwachung festgestellt werden, dann kann mittels Berechnung der Reconstruction-based Contribution (RBC) [1] der Beitrag der fehlerhaften Komponente zum berechneten statistischen Index bestimmt und die den Fehler verursachende Komponente oder der fehlerhafte Sensor lokalisiert werden. Die RBC der SPE- und Hotellings- T^2 -Statistik-Indizes werden mit den folgenden Formeln ermittelt:

$$RBC_i^{T^2} = \frac{(\xi_i^T P_{pc} \Lambda_{pc}^{-1} P_{pc}^T z)^2}{\xi_i^T P_{pc} \Lambda_{pc}^{-1} P_{pc}^T \xi_i} \quad (11)$$

$$RBC_i^{SPE} = \frac{(\xi_i^T (I - P_{pc} P_{pc}^T) z)^2}{\xi_i^T (I - P_{pc} P_{pc}^T) \xi_i}, \quad (12)$$

wobei ξ_i der Richtungsvektor entlang der i -ten Messstelle ist, $\xi_i = [0 \dots 0, 1, 0, \dots, 0]^T$, der der i -ten Spalte der Einheitsmatrix $I \in R^{m \times m}$ entspricht. Variablen, die die größten Fehleranteile aufweisen, werden als fehlerbehaftete Variablen lokalisiert [5].

1.2 Merkmalextraktion und Performanzprognose

Nachdem die fehlerhafte Komponente mit Hilfe der RBC identifiziert wurde, erfolgen weitere Untersuchungen auf Basis der Singular Spectrum Analysis (SSA) mit dem Ziel der Merkmalextraktion und -prognose. Weist mehr als ein Signal auf eine mögliche Performanzminderung hin, wird für die Merkmalextraktion die Multivariate Singular Spectrum Analysis (MSSA) [3] angewandt.

Die SSA basiert auf der Singulärwertzerlegung (singular value decomposition, SVD) und ist eine modellfreie Methode der Zeitreihenanalyse und Prognose. Hier werden die Elemente der klassischen Zeitreihenanalyse, der multivariaten Statistik, der dynamischen Systeme und Signalverarbeitung miteinander kombiniert. Mit der SSA wird das ursprüngliche Signal in eine geringe Anzahl von Komponenten zerlegt, die als Trend, Oszillation und Rauschen interpretiert werden können.

In Bild 2 ist eine grundlegende Signalzusammensetzung aus den drei Bestandteilen Trend, Oszillation und Rauschen dargestellt. Durch die Gruppierung in unterschiedlich variierende Komponenten kann der Trend des ursprünglichen Signals extrahiert werden. Mit Hilfe des auf der SSA fußenden Prognosealgorithmus kann das extrahierte Merkmal vorhergesagt werden [3]. Die Basis-SSA setzt sich aus folgenden Schritten zusammen:

- Zerlegung: Ausgangspunkt ist eine Zeitreihe $F = (f_0, f_1, \dots, f_{N-1})$ der Länge N mit einer definierten Fensterlänge L unter der Voraussetzung $1 < L < N$. Die Trajektorien-Matrix X der Zeitreihe F kann wie folgt konstruiert werden

@Autor: Der Begriff Statistik ist im englischen durchaus geläufig, im deutschen eher nicht. Was ist hier gemeint – die Verteilungsfunktion oder die Indizes? Ich vermute SPE- und Hotellings- T^2 -Indizes

@Autor: Ist der Index res richtig? Wenn SPE wirklich auf den Residuen berechnet wird, wäre Formel 12 falsch – dort ist $Z^T P_{pc} P_{pc}^T Z$ für die SPE-Indizes gesetzt

$$X = [X_1: \dots : X_k] = (x_{ij})_{i,j=1}^{L,K}, \quad (13)$$

wobei $K=N-L+1$ und $X_i=(f_{i-1}, \dots, f_{i+L-2})^T$ mit $1 \leq i \leq K$ ist. Dabei stellt die Matrix X eine Hankel-Matrix dar. Sind die Länge der Zeitreihe N und die Fensterlänge L fest, so gibt es eine Entsprechung zwischen der Hankel-Matrix und der Zeitreihe. Nach Anwendung der Singulärwertzerlegung auf die Matrix X kann die Trajektorie geschrieben werden als:

$$X = \sum_{i=1}^d \lambda_i U_i V_i^T, \quad (14)$$

mit $V_i = \frac{x^T U_i}{\sqrt{\lambda_i}}$ und $d = \max\{i, \text{so dass } \lambda_i > 0\} = \text{rank}(X)$. $\lambda_1, \dots, \lambda_d$ sind die Eigenwerte der Matrix $S=XX^T$, die in absteigender Reihenfolge ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d \geq 0$) mit den zugehörigen Eigenvektoren U_1, \dots, U_d korrespondieren. Der Ausdruck $(\sqrt{\lambda_i}, U_i, V_i)$ wird als i -ter Eigentripel der Matrix X bezeichnet. Nach der Definition $X_i = \sqrt{\lambda_i} U_i V_i^T$ mit $(i=1, \dots, d)$ kann die Singulärwertzerlegung

der Trajektorien-Matrix X wie folgt formuliert werden:

$$X = X_1 + \dots + X_d. \quad (15)$$

- **Rekonstruktion:** In diesem Schritt werden die elementaren Matrizen $X_i (i=1, \dots, d)$ in m disjunkte Untergruppen I_1, \dots, I_m unterteilt. Korrespondiert die Gruppe $I = \{i_1, \dots, i_p\}$ der Matrix X_I mit der Gruppe I so wird $X_I = X_{i_1} + \dots + X_{i_p}$ definiert. Diese Matrizen ergeben für $I=I_1, \dots, I_m$ mit der Gleichung (15):

$$X = X_{I_1} + \dots + X_{I_m} \quad (16)$$

- Die Anwendung der diagonalen Mittelwertbildung (Einzelheiten zum Verfahren der diagonalen Mittelwertbildung finden sich in [3].) auf die Matrix X_{IK} , ergibt die Zeitreihe $\tilde{F}^{(k)} = (\tilde{f}^{(k)}, \dots, \tilde{f}_{N-1}^{(k)})$. Die ursprüngliche Zeitreihe $F = (f_0, f_1, \dots, f_{N-1})$ ist somit in die Summe von m einzelnen Zeitreihen zerlegt:

Datenspur	Beschreibung Messstelle	Komponente	Einheit
1	Generator Lager 1 Temperatur	Generator	°C
2	Generator Lager 2 Temperatur	Generator	°C
3	Generator Ständer Temperatur	Generator	°C
4	Getriebe Lager 1 Temperatur	Getriebe	°C
5	Getriebe Lager 2 Temperatur	Getriebe	°C
6	Getriebe Öleinlass Temperatur	Getriebe	°C
7	Getriebe Ölsumpf Temperatur	Getriebe	°C
8	Getriebe Drehzahl	Getriebe	min ⁻¹
9	Generator Drehzahl	Generator	min ⁻¹
10	Anker Drehzahl	Anker	min ⁻¹

TABELLE 1: Liste verwendeter Prozessgrößen der Windkraftanlage




BILD 3: Sensorfehlererkennung und -lokalisierung

$$f_n = \sum_{k=1}^m \tilde{f}_n^{(k)} \quad (17)$$

Der SSA-Prognosealgorithmus wird zum Zweck der Merkmalvorhersage fortlaufend angewandt. Ausgehend von der originalen Zeitreihe $F = (f_0, f_1, \dots, f_{N-1})$ wird die rekonstruierte Zeitreihe $\tilde{F} = (\tilde{f}_0, \dots, \tilde{f}_N)$ betrachtet. Der Vektor $U^V \in R^{L-1}$ enthält die ersten $L-1$ Komponenten und π die übrigen Komponenten U_j . Durch Definition von $R = (a_{L-1}, \dots, a_1) = \left(\frac{1}{1-\nu} \sum_{i=1}^r \pi_i U_i^V\right)$, mit $\nu^2 = \pi_1^2 + \dots + \pi_r^2$, erfolgt eine fortlaufende M -Schritt-SSA-Signalvorhersage (f_N, \dots, f_{N+M-1}) wie folgt [3]:

$$f_i = \begin{cases} \tilde{f}_i & \text{for } i = 0, \dots, N-1 \\ \sum_{j=1}^{L-1} a_j f_{i-j} & \text{for } i = N, \dots, N+M-1 \end{cases} \quad (18)$$

Restnutzungsdauerschätzung

Auf der Basis verfügbaren Prozesswissens können erfahrene Systemingenieure und Anlagenfahrer Schwellwerte zur Bewertung von gewonnen Degradationssignalen ermitteln. Der Vergleich dieser vordefinierten

Schwellwerte mit den gewonnenen Degradationssignalen ermöglicht schließlich die Abschätzung der Restnutzungsdauer der untersuchten Systemkomponenten.

2. ANWENDUNGSERGEBNISSE DER VERFAHREN

Die Validierung der Verfahren zur Zustandsüberwachung wurde an Windkraftanlagen und zur Performanzprognose an Prozessen der Anlagenindustrie untersucht. Im Folgenden werden ausgewählte Ergebnisse dargestellt und erläutert.

2.1 Fehlererkennung und -lokalisierung

Die Anwendung des vorgestellten Konzeptes zur Fehlererkennung und -lokalisierung erfolgte an Windkraftanlagen gleichen Typs. Für die dargestellte Bewertung der Leistungsfähigkeit des erläuterten Konzeptvorschlags sind die ausgewählten Prozessgrößen laut Tabelle 1 der Windkraftanlagen herangezogen worden. Die Abtastrate betrug im vorliegenden Fall 10 Minuten.

Entsprechend der klassischen Unterteilung möglicher Fehlerursachen wurden Sensorfehler und Prozessfehler bezüglich der Erkennung und Lokalisierung untersucht.

Sensorfehlererkennung und Lokalisierung

Dem Instandhaltungsbericht ist ein Fehlerzustand des Sensors der Datenspur 5 (Temperatursensor Getriebe Lager 2) zum Abtastzeitpunkt 2240 zu entnehmen.

Die Prozessüberwachung auf der Basis des SPE-Index weist eine signifikante Überschreitung des Schwellwertes bereits zum Abtastzeitpunkt 2237 und somit die Anzeige eines fehlerhaften Betriebszustandes auf. Die Berechnung der RBC auf Basis der SPE-Indizes führte zur Lokalisierung der Fehlerursache. Als Ergebnis wies die Datenspur 5 den größten Fehleranteil auf, sodass auf einen Sensorfehler an der Temperaturmessstelle Getriebe Lager 2 geschlossen wurde.

Prozessfehlererkennung und -lokalisierung

Dem Instandhaltungsbericht ist ein Fehlerzustand im Kühlsystem des Getriebes zum Abtastzeitpunkt 1155 zu entnehmen.

Die Prozessüberwachung auf der Basis des T^2 -Index weist eine signifikante Überschreitung des Schwellwertes bereits zum Abtastzeitpunkt 1154 auf, sodass ein fehlerhafter Betriebszustand signalisiert wurde. Die Suche nach der Fehlerursache wurde durch die Berechnung der RBC auf Basis der T^2 -Statistik durchgeführt. Als Ergebnis zeigten die Datenspuren 5 (Getriebe Lager 2 Temperatur), 6 (Getriebe Öleinlass Temperatur) und 7 (Getriebe Ölsumpf Temperatur) vergrößerte $RBC_{T^2_{neu}}$

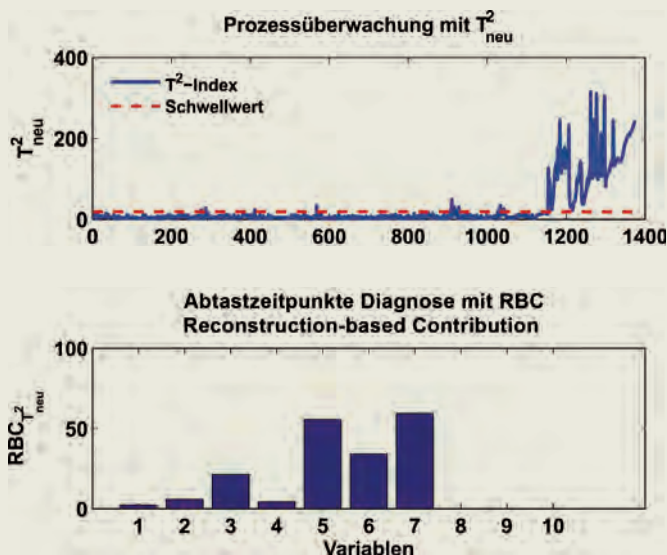


BILD 4: Prozessfehlererkennung und -lokalisierung

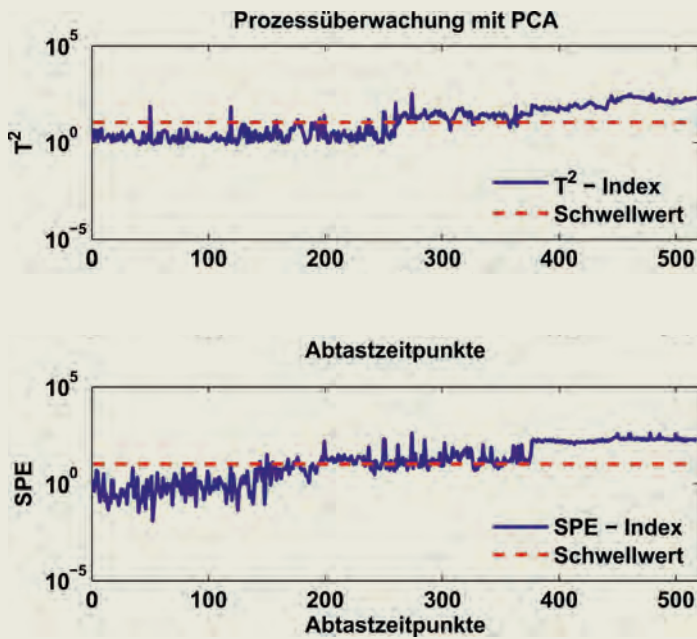


BILD 5: Prozessüberwachung mit Principal Components Analysis

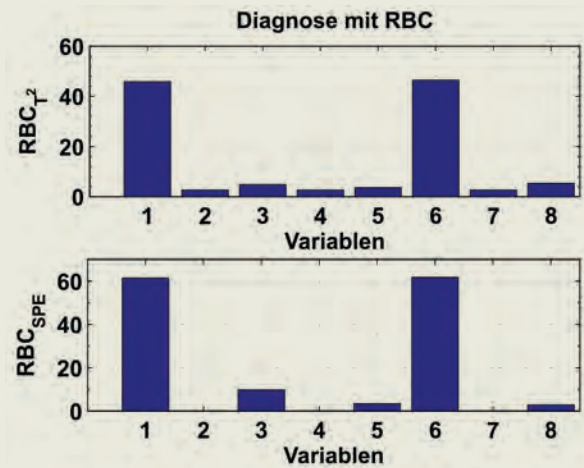
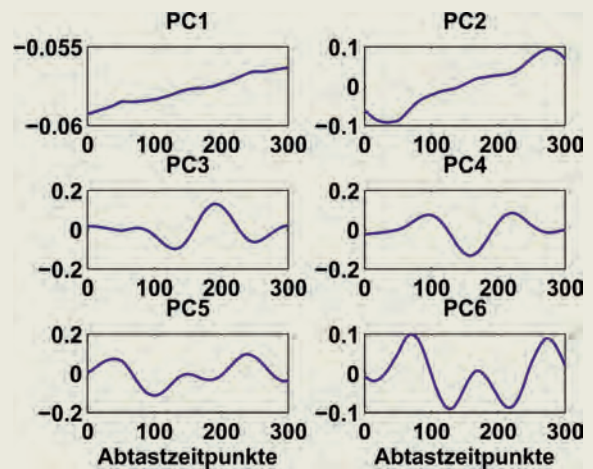


BILD 6: Lokalisation mit Reconstruction-based Contribution

BILD 7: Hauptkomponenten des Signals 1



-Anteile, was auf einen Systemfehler im Bereich des Getriebes hinwies. Auf der Grundlage dieser Lokalisierungsinformation wurden anschließend gezielte Untersuchungen der Systemkomponenten im Getriebe vorgenommen.

2.2 Performanzprognose

Die verwendeten Daten zur Validierung des Algorithmus der Performanzprognose entstammen einem Extrusionsprozess der Anlagenindustrie. Das untersuchte Fördergerät arbeitet nach dem Funktionsprinzip eines Schne-

ckenförderers, der dickflüssige Substanzen unter hohem Druck und hoher Temperatur gleichmäßig aus einer formgebenden Öffnung herauspresst. Die mechanischen Komponenten des Schneckenförderers, wie beispielsweise Welle, Lager, Getriebe und Schnecke, unterliegen aufgrund der vorliegenden Einsatzbedingungen sehr starkem Verschleiß.

Für die Durchführung der Performanzprognose standen unterschiedliche Druck- und Temperaturmessdaten mit einer Zykluszeit von 2 Stunden zur Verfügung.

Die Ergebnisse der Onlineüberwachung auf Grundlage des SPE- und T^2 -Index zeigt Bild 5. Der SPE-Index weist tendenzielle Signalveränderungen bereits zum




BILD 8: Merkmalextraktion mit Singular Spectrum Analysis

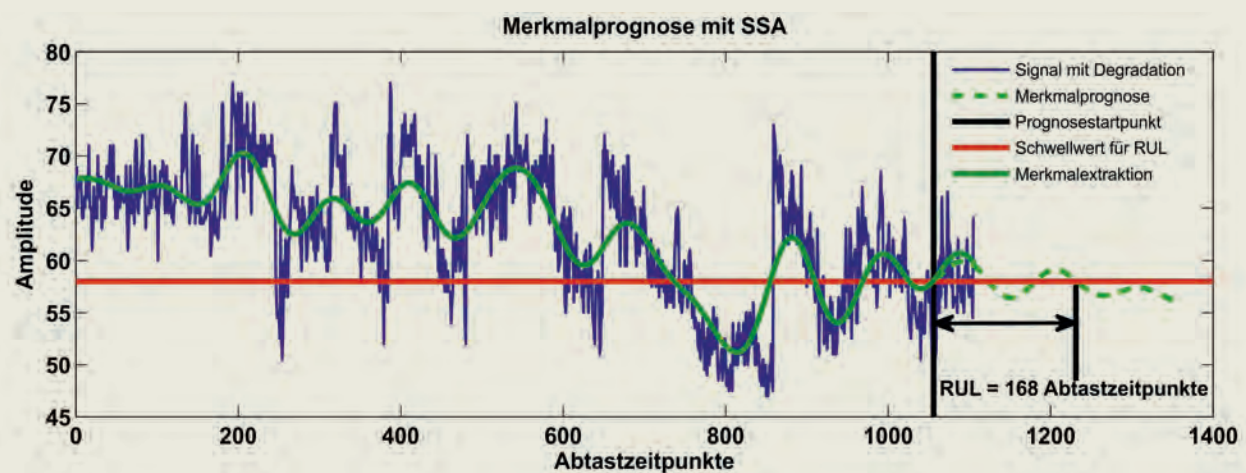


BILD 9: Performanzprognose mit Singular Spectrum Analysis

Abtastzeitpunkt 178 und der T^2 -Index zum Abtastzeitpunkt 250 auf. Die signifikante Überschreitung des berechneten Schwellwertes erfolgt durch den SPE-Index zum Abtastzeitpunkt 374 und durch den T^2 -Index zum Abtastzeitpunkt 365. Beide Indizes weisen sehr früh eine deutliche Drift im Signalverlauf auf.

Die anschließende Lokalisierung auf der Basis von SPE- und T^2 -Index mit dem RBC-Algorithmus zeigt Bild 6. Die Ergebnisse beider Indizes weisen deutlich auf die Signale 1 und 6 hin, die ursächlich für die signifikante Drift der untersuchten Indizes verantwortlich sind.

Zur Veranschaulichung des weiteren Vorgehens fokussieren sich die nachfolgenden Untersuchungen aus-

schließlich auf das Signal 1. Die Detektion des Trends aus diesem Signal erfolgt durch eine Signalzerlegung mit der gewählten Fensterlänge $L=300$ sowie einer anschließenden Signalrekonstruktion mit Hilfe der SSA. Die Zerlegung des Signals 1 in einzelne Hauptkomponenten ist exemplarisch im Bild 7 dargestellt.

Den jeweils extrahierten Trend anhand der Signalrekonstruktion von PC1 und von PC1-PC5 veranschaulicht Bild 8.

Die Durchführung der Performanzprognose erfolgt auf Grundlage der Trendentwicklung von PC1-PC5. Die Prognose für 350 Abtastzeitpunkte beginnt zum Abtastzeitpunkt 1065 und wird im Bild 9 dokumentiert.

Die definierte Schwelle für die Wartung und Instandhaltung ist mit einer Amplitude von 58 ausgewählt worden. Nach weiteren 168 Abtastzeitpunkten ab dem Startpunkt der Performanzprognose unterschreitet das prognostizierte Trendsinal die definierte Schwelle für Wartung und Instandhaltung dauerhaft. Unter Berücksichtigung der zuvor genannten Zykluszeit erfolgte somit eine Performanzprognose für die Restnutzungsdauer von 336 Produktionsstunden.

In der Praxis wurde die untersuchte Anlage bereits 112 Produktionsstunden nach dem Abtastzeitpunkt 1065 einer umfassenden Instandhaltungsmaßnahme unterzogen. Diese Instandhaltungsmaßnahme fußte auf der vorliegenden Produktionszeit des betrachteten Schneckenförderers. Hierbei wurde im prognostizierten Sektor der Anlage ein sehr starker Verschleiß der Schnecke festgestellt und diese Komponente anschließend erneuert.

ZUSAMMENFASSUNG

Im Beitrag wurden datenbasierte Verfahren zur Zustandsüberwachung und Performanzprognose vorgestellt, diskutiert und an zwei technischen Anlagen validiert. Der Nachweis der Leistungsfähigkeit des dargestellten Konzepts erfolgte anhand von Messdaten mehrerer Windkraftanlagen gleichen Typs. Ausgewählte Beispiele zur Detektion signifikanter Abweichungen

vom Nominalverhalten beim Auftreten von Sensor- und Prozessfehlern wurden exemplarisch dargelegt.

Der zweite Teil des Beitrages widmete sich der Performanzprognose von technischen Anlagen. Hier liegt der Fokus auf den Forderungen der Anlagenindustrie, eine zuverlässige Vorhersage für die sichere Funktionsfähigkeit von Anlagen zu treffen, um Wartungs- und Instandhaltungsmaßnahmen auch unter wirtschaftlichen Aspekten exakt zu planen. Der dargestellte datenbasierte Ansatz zur Performanzprognose wurde an einem Beispielprozess der Anlagenindustrie validiert. Ausgehend von einer datengestützten Prozessüberwachung auf Basis der Hauptkomponentenanalyse wurde eine Drift des Betriebszustandes erfasst. Mit Hilfe der RBC ließen sich die zur Drift der Performanzkenngröße beitragenden relevanten Prozessgrößen identifizieren. Anschließend wurde eine Extraktion der Signalmerkmale und die Vorhersage mit den Methoden der SSA/MSSA durchgeführt. Anhand von Expertenwissen der Anlagenbetreiber war es möglich, einen Schwellwert für die Restlebensdauer zu definieren, sodass sich eine erfolgreiche Performanzprognose durchführen ließ.

Die vorgestellten Verfahren zur Zustandsüberwachung und Performanzprognose eröffnen somit neue Möglichkeiten für die Entwicklung fehlertoleranter Systeme und Anlagen. Darüber hinaus besteht mit dem Verfahren der Performanzprognose die Möglichkeit, eine Abschätzung der Restlebensdauer auf der Basis von Prozessdaten durchzuführen.

AUTOREN

M.Sc. **MINJIA KRÜGER** (geb. 1986) ist Mitarbeiterin des Fachgebiets Automatisierungstechnik und Komplexe Systeme der Fakultät Ingenieurwissenschaften an der Universität Duisburg-Essen. Hauptarbeitsgebiete: Modellgestützte Prozessüberwachung, fehlertolerante Systeme.

**Institut für Automatisierungstechnik und Komplexe Systeme, Universität Duisburg-Essen,
Bismarckstraße 81 BB,
D-47057 Duisburg,
Tel. +49 (0) 203 379 42 95,
E-Mail: minjia.krueger@uni-due.de**

Prof. Dr.-Ing. **TORSTEN JEINSCH** (geb. 1970) ist Inhaber des Lehrstuhls Regelungstechnik im Institut für Automatisierungstechnik an der Fakultät für Informatik und Elektrotechnik der Universität Rostock. Hauptarbeitsgebiete: fehlertolerante Systeme, adaptive Systeme, optimale Steuerung.

**Institut für Automatisierungstechnik,
Universität Rostock,
Richard-Wagner-Straße 31, Haus 8,
D-18119 Warnemünde,
Tel. +49(0) 381 498 77 04,
E-Mail: torsten.jeinsch@uni-rostock.de**

Die Autoren des Beitrages entwickeln aktuell fehlertolerante Systeme mit dem Ziel, temporäre Prozesseingriffe vorzuschlagen und durchzuführen, um in Abhängigkeit der prognostizierten Performanzdegradation weitere Entscheidungskriterien zu berücksichtigen. Diese Eingriffe könnten zum Beispiel die Produktqualität oder -quantität vorübergehend senken, jedoch aus wirtschaftlicher Sicht erhebliche Vorteile gegenüber einem sofortigen Produktionsstopp zur Durchführung von Wartung und Instandhaltung darstellen. Mit dieser Entwicklung soll künftig der Entscheidungsprozess von Betriebsingenieuren automatisiert unterstützt werden, um zum Beispiel gezielte Maßnahmen nach dem Erfassen einer fehlerhaften Komponente im System einzuleiten.

MANUSKRIPTEINGANG
10.03.2014

Im Peer-Review-Verfahren begutachtet

DANKSAGUNG

Die präsentierten Ergebnisse wurden im Rahmen des Förderprogramms zum Zentralen Innovationsprogramm Mittelstand (ZIM) unter dem Titel „Entwicklung eines neuen adaptiven Verfahrens und Systems für das technische Anlagenmanagement von Industrieanlagen“ erarbeitet.

REFERENZEN

- [1] Alcalá, C.F., Qin, S.J.: Reconstruction-based contribution for process monitoring. *Automatica* 47(7), S. 1593-1600, 2009
- [2] Ding, S.X., Zhang, P., Jeinsch, T., Ding, E., Engel, P., Wei, P.: A survey of the application of basic data-driven and model-based methods in process monitoring and fault diagnosis. In: Preprints 18th IFAC World Congress, S. 12380-12388. IFAC 2011
- [3] Golyandina, N., Nekrutkin, V., Zhigljavsky, A.: Analysis of time series structure SSA and related techniques. CRC press, 2001
- [4] Russell, E., Chiang, L.H., Braatz, R.D.: Data-driven methods for fault detection and diagnosis in chemical processes. Springer 2000
- [5] Valle, S., Li, W., Qin, S.: Selection of the number of principal components: The variance of the reconstruction error criterion with a comparison to other methods. *Industrial and Engineering Chemistry Research* 38(11), S. 4389-4401, 1999
- [6] Hameed, Z., Hong, Y. S., Cho, Y. M., Ahn, S. H., Song, C. K.: Condition monitoring and fault detection of wind turbines and related algorithms: A review. *Renewable and Sustainable energy reviews* 13(1), S. 1-39, 2009
- [7] Krüger, M., Ding, S.X., Haghani, A., Jeinsch, T., Engel, P.: Datenbasiertes Verfahren zur erweiterten Zustandsüberwachung von Windkraftanlagen. *VDI-Berichte* 2209, S. 227-230, 2013
- [8] Krüger, M., Stargala, T., Jeinsch, T., Engel, P., Ding, S.X.: Überwachung und Prognose der Leistungsentwicklung von Industrieanlagen mittels datenbasierter Verfahren. In: Tagungsband AALE 2013, S. 135-142. Deutscher Industrieverlag 2013
- [9] Jeinsch, T., Engel, P., Ding, S.X., Schoch, D., Neumann, H.: Statistische Verfahren zur Fehlererkennung und -diagnose. *atp edition – Automatisierungstechnische Praxis* 52(6), S. 10-13, 2010

Dr.-Ing. **ADEL HAGHANI** (geb.1981) ist Mitarbeiter des Lehrstuhls Regelungstechnik im Institut für Automatisierungstechnik an der Fakultät für Informatik und Elektrotechnik der Universität Rostock. Hauptarbeitsgebiete: fehlertolerante Systeme, datenbasierte Verfahren zur Prozessüberwachung

**Institut für Automatisierungstechnik,
Universität Rostock,
Richard-Wagner-Straße 31, Haus 8,
D-18119 Warnemünde,
Tel. +49 (0) 381 498 77 09,
E-Mail: adel.haghani@uni-rostock.de**

Dr.-Ing. **PETER ENGEL** (geb. 1962) ist verantwortlich für Konzeption und Entwicklung des Produkts *zedas@asset* bei der PC-Soft GmbH sowie für diverse Forschungs- und Entwicklungsprojekte mit Hochschulen.

**PC-Soft GmbH,
Adolf-Hennecke-Str. 37,
D-01968 Senftenberg,
Tel. +49 (0) 3573 70 75 20,
E-Mail: pengel@pcsoft.de**

Prof. Dr.-Ing. **STEVEN X. DING** (geb. 1959) leitet das Fachgebiet Automatisierungstechnik und Komplexe Systeme der Fakultät Ingenieurwissenschaften an der Universität Duisburg-Essen. Hauptarbeitsgebiete: Modellgestützte Prozessüberwachung, fehlertolerante Systeme und Anwendung in der Automobilindustrie.

**Institut für Automatisierungstechnik und
Komplexe Systeme,
Universität Duisburg-Essen,
Bismarckstraße 81 BB,
D-47057 Duisburg,
Tel. +49 (0) 203 379 33 86,
E-Mail: steven.ding@uni-due.de**