

# Zustandsüberwachung in der Automatisierungstechnik mittels maschinellem Lernen

*Steffen Klein<sup>1</sup>, Tizian Schneider<sup>1</sup>, Andreas Schütze<sup>2</sup>*

<sup>1</sup>*ZeMA – Zentrum für Mechatronik und Automatisierungstechnik gGmbH, Saarbrücken, Deutschland*

<sup>2</sup>*Universität des Saarlandes, 66123 Saarbrücken, Deutschland*

## Zusammenfassung

Ziel des vom BMBF geförderten Verbundprojekts MoSeS-Pro war die Entwicklung eines modularen Sensorsystems für die Echtzeitprozesssteuerung und die smarte Zustandsbewertung. Basis dieses Sensorsystems ist ein modularer Hard- und Softwarebaukasten, welcher je nach Anforderung der spezifischen Anwendung verschiedenste Kombinationen von Sensoren und Algorithmen gestattet. Der entwickelte Softwarebaukasten kombiniert dabei fünf verschiedene Methoden der Merkmalsextraktion mit drei Ansätzen zur Merkmalselektion, wodurch unabhängig von der Herkunft der Daten ein nahezu ideales Klassifikationsergebnis erreicht wird. Die Leistungsfähigkeit des Baukastens wurde innerhalb des Projektes am Beispiel der Lebensdauerprognose von elektromechanischen Zylindern demonstriert. Hierzu wurde ein Lebensdauerprüfstand für elektromechanische Zylinder entwickelt, wodurch Signale verschiedenster Sensoren über die gesamte Lebensdauer des Zylinders aufgezeichnet werden können. Die Auswertung der Daten zeigt, dass für einzelne Zylinder eine hochaufgelöste Verschleißdetektion möglich ist, die eine Zustandsbewertung mit einer Auflösung von einem Prozent der Gesamtlebensdauer ermöglicht. Auch bei einem kombinierten Modell, gebildet aus Daten von mehreren baugleichen elektromechanischen Zylindern, können Merkmale identifiziert werden, welche charakteristische Informationen über den Verschleißfortschritt liefern.

**Keywords:** Zustandsüberwachung, vorausschauende Instandhaltung, maschinelles Lernen, Big Data, Industrie 4.0

## Einführung und Motivation

Mit steigender Leistungs- und Funktionsdichte technischer Systeme verknüpfen sich besondere Anforderungen bezüglich Verfügbarkeit, Wirtschaftlichkeit und Sicherheit. Diese Anforderungen können durch klassische Instandhaltungsstrategien, wie präventive Wartungen oder starre Inspektionsintervalle zunehmend nicht mehr erfüllt werden. Dadurch könne hohe Kosten infolge von Produktionsausfällen oder nicht vollständig ausgenutzten Abnutzungsvorräten entstehen. Für Anlagenbetreiber werden deshalb Strategien der vorausschauenden, zustandsbasierten Instandhaltung von immer höherem Interesse [1].

Die Umsetzung dieser neuen Strategien basiert auf der Entwicklung zuverlässiger Diagnosesysteme, welche Aussagen über den Betriebszustand einzelner Komponenten komplexer Maschinen erlauben. Neben der geeigneten Sensorik zur Messung maschinenspezifischer Parameter bestehen solche Systeme aus Methoden und Algorithmen zur Bewertung von Schädigungs- und Degradationsmechanismen. In diesem Zusammenhang kommen neuerdings bevorzugt Verfahren der signalana-

lytischen und modellbasierten Zustandsdiagnose aus dem Bereich des maschinellen Lernens zur Anwendung. Diese sollen eine Prognose über die verbleibende Restlaufzeit erlauben, wodurch Ausfälle prognostiziert und Instandhaltungsmaßnahmen in ohnehin vorhandene Stillstandszeiten verlegt werden können [2].

Die Entwicklung eines solchen Sensorsystems für die Echtzeit-Prozesssteuerung und smarte Zustandsbewertung für die Industrie 4.0 war Inhalt des BMBF Projekts MoSeS-Pro. Basis dieses Systems ist ein modularer Hard- und Software-Baukasten, welcher je nach Anforderungen der spezifischen Anwendung verschiedenste Kombinationen von Sensoren und Algorithmen gestattet. Die dabei umgesetzte sensornahe Signalverarbeitung vereinfacht eine direkte Integration in industrielle IT-Infrastrukturen durch Übermittlung weniger, hoch verschleißrelevanter Merkmale. Der Einsatz automatisierter, maschineller Lernalgorithmen erlaubt gleichzeitig eine schnelle Anpassung an verschiedene Anwendungsszenarien. Im Rahmen des Projektes wurde die Leistungsfähigkeit der Algorithmen am Beispiel der Zustandsüberwachung von elektromechani-

schen Zylindern demonstriert. Anwendung finden diese hauptsächlich in Positionier-, Montage- und Handhabungssystemen in der Automatisierungstechnik, wobei durch die Kombination von hohen Vorschubkräften und hoher Positioniergenauigkeit auch ein Einsatz in umformenden Prozessen (z. B. Pressaufgaben) möglich ist [3].

### Lebensdauerprüfstand

Um die für das maschinelle Lernen benötigte Datenbasis zu generieren, wurde ein Lebensdauerprüfstand entwickelt, welcher das Verfahren des elektromechanischen Zylinders unter kontrollierten Bedingungen ermöglicht. In Abb. 1 a) ist der Prüfstand dargestellt. Hierbei können Verfahrenprofile anhand verschiedener Parameter, wie Geschwindigkeit, Beschleunigung oder zu leistender Hub über eine LabVIEW-Software konfiguriert werden. Gleichzeitig besteht die Möglichkeit, die Kolbenstange der Spindelachse mit Kräften in Vorschubrichtung zu belasten, wodurch Einfluss auf die Ausbreitungsgeschwindigkeit der Verschleißmechanismen genommen werden kann. Die axiale Belastung des Zylinders ist über einen Pneumatikzylinder realisiert, welcher, wie in Abb. 1 b) gezeigt, mit der Kolbenstange des elektromechanischen Zylinders gekoppelt ist.




Abb. 1: Gesamtansicht Lebensdauerprüfstand für elektromechanische Zylinder (links), Kopplung von Prüfling und variabler Last in Form eines Pneumatikzylinders (rechts) [4].

### Prüfstandssensorik

Um den Verschleißfortschritt des Prüflings über den Lebensdauerversuch zu erfassen, werden einerseits zu Regelzwecken ohnehin vorhandene Sensoren sowie antriebsbasierte Signale des Motorcontrollers verwendet, andererseits wird auf dedizierte Sensoren in Orientierung an die Wälzlagerdiagnose zurückgegriffen. Dabei erfolgt zunächst eine bewusste Überinstrumentierung in Bezug auf die Anzahl und Abtastrate der Sensoren, um den Informationsgehalt der verschiedenen Signale im Hinblick auf fortschreitende Verschleißmechanis-

men an der Spindelachse zu identifizieren. In der praktischen Anwendung muss dann eine Reduzierung der verwendeten Sensorik auf ein wirtschaftliches Maß stattfinden.

Bei den verwendeten Körperschallsensoren handelt es sich um uniaxiale IEPE (Integrated Electronic Piezo Electric) Beschleunigungsaufnehmer (Kistler) mit einer Bandbreite von 24 kHz. Um einen möglichst steifen Körperschallpfad zwischen Schwingungsursache und Sensor zu erreichen, werden die Beschleunigungsaufnehmer nah an ausfallrelevanten Komponenten des elektromechanischen Zylinders, also Kugellager, Gleitlager und Kugelgewindetrieb befestigt, Abb. 2. Da kein Sensor direkt an den Kugelgewindetrieb gekoppelt werden kann, wird dieser an einem Adapterstück an der Kolbenstange angebracht, welche durch eine Schraubverbindung im Inneren des elektromechanischen Zylinders eine starre Verbindung zum Kugelgewindetrieb aufweist.




Abb. 2: Positionierung der Beschleunigungssensoren am Prüfling [3]

Neben den Beschleunigungssensoren wird zusätzlich ein Ultraschallmikrofon (G.R.A.S) eingesetzt, um höherfrequente Anteile im Luftschall bis 100 kHz zu erfassen.

Um antriebsbasierte Signale, wie z. B. die Motorströme auf ihre Tauglichkeit zur Zustandsbewertung von elektromechanischen Zylindern zu untersuchen, werden die drei Phasen des Antriebsmotors mittels externer Stromsensoren des Typs CMS205 (Sensitec) gemessen.

Tab. 1 gibt eine Übersicht über alle zur Verfügung stehenden Sensorsignale sowie die dazugehörigen Abtastraten der Datenerfassung.

Tab. 1: Prüfstandssensorik und zugehörige Abtastraten der Datenerfassung

Sensorart	Messgröße	Abtastrate
Dedizierte Sensorik	Beschleunigung Gleitlager	100 kHz
	Beschleunigung Kugellager	
	Beschleunigung Kolbenstange	
	Luftschall	
Antriebsbasierte Signale	Motorstrom (U, V, W)	1 MHz
	Verfahrensgeschwindigkeit	10 kHz
	Wirkstrom	10 kHz
Prozesssensorik	Axialkraft	10 kHz
	Druck Pneumatikzylinder	10 kHz

## Lebensdauerversuche

Die im Rahmen des Projektes durchgeführten Lebensdauerversuche, dienen der realitätsnahen Nachbildung von Schadens- und Verschleißbildern elektromechanischer Zylinder über ihre Lebensdauer. Der Ablauf der Versuche orientiert sich an einer für elektromechanische Zylinder typischen zyklischen Arbeitsweise. In Abb. 3 ist exemplarisch ein Arbeitszyklus des elektromechanischen Zylinders anhand der Verfahrgeschwindigkeit dargestellt.




Abb. 3: Arbeitszyklus des elektromechanischen Zylinders dargestellt anhand der Verfahrgeschwindigkeit; markiert ist die Gleichlaufphase des Rückhubs, die für die Zustandsbewertung ausgewertet wird.

Während der Versuche sind die Prüflinge durch die Kombination von hohen Verfahrgeschwindigkeiten (200 mm/s), Beschleunigungen (5 m/s<sup>2</sup>) und Axialkräften (ca. 7 kN) im Bereich der Spezifikationsgrenzen hohen Belastungen ausgesetzt. Dadurch werden ein möglichst schneller Verschleißfortschritt und ein daraus resultierender Ausfall provoziert. Ein Überschreiten von festgelegten Grenzen, z. B. der Schleppfehlergrenze bei einer durchgeführten Lageregelung, stellt das Ausfallkriterium für die Spindelachsen dar. Wird ein solcher Grenzwert während des Betriebs überschritten, wird der Versuch automatisch gestoppt und die Spindelachse gilt als defekt. Um eine bestmögliche Vergleichbarkeit der Versuche zu erreichen, wurden die hier betrachteten Lebensdauerversuche unter identischen Bedingungen und Konfigurationen durchgeführt. Tab. 2 gibt eine Übersicht über die Ergebnisse der hier betrachteten Lebensdauerversuche anhand der Laufzeit und der erreichten Arbeitszyklen. Durch die starke Überinstrumentierung des Prüfstandes fallen enorme Datenmengen für die Lebensdauerversuche an, was

sich in einem Datenvolumen von ca. 12 TB pro Lebensdauerversuch äußert.

Tab. 2: Vergleich der betrachteten Lebensdauerversuche anhand Laufzeit und erreichter Arbeitszyklen

Lebensdauerversuch Nr.	Laufzeit [Tage]	Anzahl Arbeitszyklen
1	20,4	629.151
2	19,6	603.627
3	18,6	572.750

## Modularer Softwarebaukasten

Die Auswertung bzw. Modellbildung erfolgt mittels eines am Zentrum für Mechatronik und Automatisierungstechnik entwickelten vollautomatisierten Methodenbaukastens zum überwachten maschinellen Lernen. Dieser kombiniert fünf Methoden der Merkmalsextraktion (ME) mit drei Ansätzen zur Merkmalsselektion (MS). Durch anschließende Dimensionsreduktion und Klassifikation wird mittels 10-fach Kreuzvalidierung der minimale Klassifikationsfehler für sämtliche Kombinationen bestimmt und die bestmöglichen Methoden für den jeweiligen Datensatz identifiziert [5].

Um ein nahezu ideales Klassifikationsergebnis unabhängig von der Herkunft des Datensatzes zu erreichen, wurden komplementäre Methoden für die ME ausgewählt. Ziel der ME ist es dabei stets, das Rohsignal mit möglichst wenigen Merkmalen und minimalem Rekonstruktionsfehler abzubilden. Welche Methode dabei erfolgreich ist, hängt stark von der Herkunft des betrachteten Signals ab. So bildet beispielsweise die Adaptive Linear Approximation (ALA) lokale Details in Zeitreihen ab, wohingegen periodische Sensorsignale häufig besser durch Beste Fourier Koeffizienten (BFC) im Frequenzbereich repräsentiert werden. Genauere Information zu den implementierten ME-Methoden können [5] entnommen werden. Neben der möglichst generalisierbaren Anwendbarkeit wurde bei der Auswahl der Methoden für die ME vor allem darauf geachtet, dass sie später sensornah auf einem Mikroprozessor bzw. einer FPGA implementiert werden können. Dadurch entfällt bei der Anwendung der Algorithmen in der Zustandsüberwachung die Notwendigkeit, umfangreiche Rohdaten auf höhere Systemebenen der Prozesssteuerung transferieren zu müssen. Stattdessen werden nur noch wenige charakteristische, in der Trainingsphase identifizierte Merkmale übertragen.

Auch bei der MS kommen komplementäre Algorithmen zum Einsatz. Neben der Pearson Korrelation werden recursive feature elimination support vector machines (RFESVM) sowie RELIEFF für die MS eingesetzt. RFESVM



eignet sich vor allem bei linearer Trennbarkeit der Klassen, wobei auch die Merkmalsinteraktion berücksichtigt wird. Im Gegensatz dazu basiert RELIEFF auf einer radialen Klassifikation, was sie für nichtlineare Klassifikationsprobleme nutzbar macht. Auch zu den MS Algorithmen können weiterführende Informationen aus [5] entnommen werden.




Abb. 4: Vollautomatisierter Methodenbaukasten mit komplementären Methoden für Merkmalsextraktion (links), -selektion (Mitte) und Klassifikation (rechts)

Die abschließende Dimensionsreduktion und Klassifikation erfolgt mittels Linearer Diskriminanzanalyse (LDA) in Kombination mit einem Mahalanobis-Distanz Klassifikator. Durch den Einsatz vergleichsweise einfacher, linearer Verfahren im Schritt der Mustererkennung bleibt im Gegensatz zu Blackbox-Verfahren, wie z. B. neuronalen Netzen, die Möglichkeit erhalten, eine spätere physikalische Plausibilisierung des Modells und der selektierten Merkmale durchzuführen.

### Zustandsbewertung für einzelne elektromechanische Zylinder

Im Folgenden werden die Ergebnisse der Zustandsbewertung einzelner elektromechanischer Zylinder exemplarisch anhand des ersten Lebensdauerversuchs vorgestellt. Die Daten des Lebensdauerversuchs werden dazu in 1% Schritte der Gesamtlebensdauer des elektromechanischen Zylinders unterteilt und mittels des beschriebenen Methodenbaukastens ausgewertet, wobei jeweils nur die Gleichlaufphase des Rückhubs, wie in Abb. 3 dargestellt, verwendet wird. In Abb. 5 sind die kreuzvalidierten Klassifikationsfehler der einzelnen FE-Methoden nach Merkmalsselektion mittels Pearson-Korrelation über die Anzahl der zur Modellbildung verwendeten Merkmale dargestellt. Ausgewertet werden dabei die Einzelzyklen, was einer Bewertung des Zustandes des elektromechanischen Zylinders alle 2,8 Sekunden, entsprechend der Dauer des konfigurierten Arbeitszyklus, entspricht.




Abb. 5: Kreuzvalidierte Klassifikationsergebnisse der einzelnen ME-Methoden; Merkmalsselektion mittels Pearson-Korrelation, Klassifikation mittels LDA und Mahalanobis-Distanz

Der minimale erreichte Klassifikationsfehler beträgt 9% unter Verwendung von 499 Merkmalen. Erreicht wird dies über die Extraktion der besten Fourierkoeffizienten (BFC), wobei Frequenzen mit dem höchsten Mittelwert über alle Arbeitszyklen ausgewertet werden [6]. Diese beinhalten die meiste Signalenergie und tragen deshalb am meisten zur Minimierung des Rekonstruktionsfehlers bei.

Im Sinne einer vorausschauenden Instandhaltung wird eine Abschätzung der verbleibenden Restlaufzeit des elektromechanischen Zylinders alle 2,8 Sekunden nicht benötigt. Abb. 6 zeigt aus diesem Grund die 10-fach kreuzvalidierte Vorhersage bei einer Zustandsbewertung durch einen Mehrheitsentscheid über die letzten 15 Minuten. Dadurch kann der verbleibende Klassifikationsfehler auf 5% reduziert werden, wobei der Großteil der Fehlklassifikationen an den Quantisierungsstufen auftritt, was einer fehlerhaften Zustandsbewertung von  $\pm 1\%$  der Gesamtleistung des elektromechanischen Zylinders entspricht. Lediglich am Ende der Lebensdauer erfolgt eine zu frühe Prognose des Ausfalls, was auch durch den Mehrheitsentscheid nicht korrigiert werden kann.

Wie bereits erläutert, erlauben die hier verwendeten Methoden eine Analyse der zur Modellbildung verwendeten Merkmale. In Abb. 7 ist die Herkunft der 499 besten Merkmale nach den zugrundeliegenden Sensoren aufgeschlüsselt. Hier wird deutlich, dass die bei der Wälzlagerdiagnose bereits etablierten Sensoren auch bei der Zustandsüberwachung von elektromechanischen Zylindern den größten Beitrag liefern. Neben Merkmalen, die aus dem Signal des Ultraschallmikrofons gewonnen werden, liefern vor allem die Beschleunigungs-

sensoren hoch mit dem Verschleiß korrelierte Merkmale. Die Analyse dieser Merkmale zeigt, dass ebenfalls eine physikalische Interpretation und Plausibilisierung dieser Merkmale erfolgen kann. So stammt ein Großteil der selektierten Merkmale aus Frequenzen, welche mechanische Antriebsfrequenzen, Überrollfrequenzen oder deren Harmonische als Ursache haben.




Abb. 6: Lebensdauervorhersage des elektromechanischen Zylinders durch Mehrheitsentscheid über die letzten 15 Minuten




Abb. 7: Herkunft der zur Modellbildung verwendeten Merkmale aufgeschlüsselt nach den Sensoren

Eine weitere Art der Plausibilisierung des Modells ist in Abb. 8 dargestellt. Hier erfolgt die Modellbildung in 20% Schritten (Trainingsdaten 1%, 21%, 41%, 61%, 81%) der Gesamtleistung des elektromechanischen Zylinders. Verwendet wurden dabei die 60 höchstkorrelierten Merkmale. Anschließend werden Testdaten (10%, 30%, 50%, 70%, 90%) projiziert. Diese liegen, wie in Abb. 8 gezeigt, an den zu erwartenden Positionen zwischen den Trainingsdaten, obwohl die Reihenfolge der Klassen nicht als Eingangsinformation bei der

Modellbildung vorgegeben wurde. Diese Art der Gruppen-basierten Validierung zeigt deutlicher als die übliche Kreuzvalidierung das Potential des Modells zur korrekten Interpolation von Verschleißdaten [6].




Abb. 8: Verlauf der LDA-Projektion bei zunehmendem Verschleiß des elektromechanischen Zylinders, bei Bildung des Modells in 20% Schritten der Lebensdauer und Projektion von Testdaten

### Zustandsbewertung einzelner elektromechanischer Zylinder auf Basis des Motorstroms

Um das Potential rein antriebsbasierter Signale für die Zustandsüberwachung elektromechanischer Zylinder zu überprüfen, wurde eine Auswertung auf Basis der externen Stromsensoren durchgeführt. Im Vergleich zur restlichen Sensorik wird der Motorstrom zu Regelzwecken im Motorcontroller ohnehin erfasst, was die Integration einer Zustandsüberwachung in den Motorcontroller ohne großen Mehraufwand ermöglichen würde. Abb. 9 zeigt wieder die 10-fach kreuzvalidierte Vorhersage durch Mehrheitsentscheid über die letzten 15 Minuten rein auf Basis der Stromsensoren.

Der verbleibende Klassifikationsfehler beläuft sich hierbei auf 6%, was eine nur minimale Verschlechterung der Vorhersagegenauigkeit des Modells im Vergleich zur gesamten Prüfstandssensorik mit Beschleunigungssensoren und Mikrofon bedeutet. Auch hier treten neben dem zu früh vorhergesagten Ausfall gegen Ende der Lebensdauer die Fehlklassifikationen hauptsächlich an den Quantisierungsstufen auf. Die selektierten Merkmale stammen wieder vorwiegend aus Frequenzen mit mechanischen Ursachen, welche sich durch den gesamten Antriebsstrang vom elektromechanischen Zylinder bis hin zum Stator des Antriebsmotors fortsetzen und somit von den Stromsensoren erfasst werden können [7].




Abb. 9: Lebensdauervorhersage des elektromechanischen Zylinders durch Mehrheitsentscheid über die letzten 15 Minuten nur auf Basis der Stromsensoren

#### Kombiniertes Modell baugleicher elektromechanischer Zylinder auf Basis des Motorstroms

Um die gebildeten datengetriebenen Modelle im Rahmen einer Lebensdauerprognose nutzbar zu machen, muss eine Übertragbarkeit der Modelle zwischen baugleichen elektromechanischen Zylindern gegeben sein. Im ersten Schritt muss dazu ein Modell bzw. Merkmale gefunden werden, welche zylinderübergreifend charakteristisch den Verschleiß über die Lebensdauer widerspiegeln. Um diesen Sachverhalt zu untersuchen, wurde ein gemeinsames Modell aus den Motorstromsignalen der drei in Tab. 2 gezeigten Lebensdauerversuche gebildet. Bei der Analyse der Daten hat sich gezeigt, dass die Einlaufphasen nach Inbetriebnahme sowie die Signale kurz vor dem Ausfall der Achse sehr spezifisch für die einzelnen Zylinder sind. Aus diesem Grund wurden für die Bildung des kombinierten Modells

die Einlaufphasen (jeweils erste 10% der Lebensdauer) sowie die Ausfallphasen (jeweils letzte 4%) der einzelnen Zylinder bei der Modellbildung herausgelassen. In Abb. 10 ist die 10-fach kreuzvalidierte Vorhersage für das kombinierte Modell auf Basis der Stromsensoren für die drei Lebensdauerversuche dargestellt. Wie hier zu sehen ist, kann ein konsistentes Modell für alle drei Achsen bestimmt werden, wobei die Vorhersagequalität für die einzelnen Zylinder durchaus unterschiedlich ausfällt: am besten wird die Restlebensdauer für den 2. Versuch vorhergesagt.

#### Diskussion und Ausblick

Im Rahmen des Projektes MoSeS-Pro wurde eine flexibel einsetzbare modulare Softwaretoolbox für das automatisierte maschinelle Lernen entwickelt, welche neben dem hier gezeigten Anwendungsfall schon auf einer Vielzahl an Datensätzen erfolgreich getestet wurde [8]. Die Implementierung dieser Algorithmen auf einer ebenfalls in MoSeS-Pro entwickelten modularen Hardwarebasis erlaubt eine sensornahe Signalverarbeitung, was eine drastische Reduzierung der zu übertragenden Datenmengen bedeutet, da nur noch einzelne aussagekräftige Merkmale in höhere Systemebenen übertragen werden müssen. Die infolgedessen deutlich geringeren benötigten Datenraten ermöglichen z. B. die Vernetzung der Sensoren mittels Wireless-Schnittstellen.

Im Falle der Zustandsbewertung für elektromechanische Zylinder konnte für einzelne Zylinder eine hochaufgelöste Verschleißdetektion bzw. Vorhersage der Restlebensdauer erreicht werden. Vor allem eine auf den Stromsignalen des Antriebsmotors basierende Modellbildung erscheint vielversprechend, da im Gegensatz zur verwendeten externen Sensorik keine zusätzliche Sensorik, z. B. ein Ultraschallmikrofon, in das System integriert werden muss.




Abb. 10: Lebensdauervorhersage des kombinierten Modells der drei Lebensdauerversuche durch Mehrheitsentscheid über die letzten 15 Minuten auf Basis der Stromsensoren

Um die vorgestellten datengetriebenen Modelle für die Zustandsbewertung nutzbar zu machen, ist vor allem im Bereich der Übertragbarkeit noch Arbeit zu leisten. Wie gezeigt, ist die Bildung eines konsistenten, zylinderübergreifenden Modells möglich, allerdings auf Kosten der Vorhersagegenauigkeit für die einzelnen Zylinder. Für eine praktische Zustandsbewertung müsste allerdings eine generelle Übertragbarkeit der Modelle gegeben sein. Hierfür würde in erster Linie eine breitere Datenbasis benötigt, um Fertigungstoleranzen individueller elektromechanischer Zylinder zu unterdrücken. Des Weiteren müssten Experimente mit anderen Arbeitszyklen durchgeführt werden, um die Auswirkungen z. B. von veränderten Last- oder Geschwindigkeitsprofilen festzustellen. Neben dem hier präsentierten Methodenbaukasten für das überwachte maschinelle Lernen müssen für eine zuverlässige Zustandsbewertung Methoden der Novelty Detection bzw. des unüberwachten maschinellen Lernens ergänzt werden. Dadurch sollen in der Praxis unbekannte System(fehler)zustände detektiert werden, welche nach Identifikation ihrer Ursache nach und nach in das Zustandsüberwachungsmodell eingelernt werden.

### Danksagungen

Die Arbeiten wurden mit Mitteln des Bundesministeriums für Bildung und Forschung im Rahmen des Verbundprojekts MoSeS-Pro unter dem Förderkennzeichen 16ES0419K gefördert. Die elektromechanischen Zylinder sowie die Komponenten des Prüfstands wurden von der Firma Festo im Rahmen der Zusammenarbeit zur Verfügung gestellt.

### Literaturnachweis

- [1] VDMA, Am Puls der Maschine: Condition Monitoring, VDMA Verlag, 2015.
- [2] M. Walther, Antriebsbasierte Zustandsdiagnose von Vorschubantrieben, Dissertation, Universität Stuttgart, Fakultät für Maschinenbau, Stuttgart, 2011
- [3] Festo AG & Co KG, Datenblatt ESBF elektromechanischer Zylinder, Online verfügbar: [https://www.festo.com/cat/en\\_gb\\_gb/data/doc\\_DE/PDF/DE/ESBF\\_DE.PDF](https://www.festo.com/cat/en_gb_gb/data/doc_DE/PDF/DE/ESBF_DE.PDF) [Zugriff am 08.01.2019].
- [4] T. Schneider, N. Helwig, S. Klein, A. Schütze, Influence of sensor network sampling rate on multivariate statistical condition monitoring of industrial machines and processes, Eurosenors 2018, Volume 2, doi: 10.3390/proceedings2130781
- [5] T. Schneider, N. Helwig, A. Schütze, Industrial condition monitoring with smart sensors using automated feature extraction and selection, Measurement Science and Technology, Volume 29, Number 9 (2018)
- [6] S. Youssef, C. Zimmer, K. Szielasko, A. Schütze, Bewertung subjektiver und automatisierter Merkmalsextraktion periodischer Zeitsignale am Beispiel des 3MA-X8-Verfahrens, tm - Technisches Messen, Online erschienen: 18.01.2019, doi: 10.1515/teme-2018-0074.
- [7] D. Miljković, Brief Review of Motor Current Signature Analysis, HDKBR INFO Magazin, vol.5, no. 1, pp. 14-26, 2015. [Online]. Available: <https://hrcak.srce.hr/148715>. [Accessed: 07 May 2019]
- [8] T. Schneider, N. Helwig, A. Schütze, Automatic feature extraction and selection for condition monitoring and related datasets, IEEE Xplore 218, doi: 10.1109/I2MTC.2018.8409763