

Synchronisationsprobleme innerhalb eines Sensorsystems und deren Auswirkungen auf Ergebnisse des maschinellen Lernens

Tanja Dorst¹, Tizian Schneider², Steffen Klein³, Sascha Eichstädt¹, Andreas Schütze^{2,3}

¹Physikalisch-Technische Bundesanstalt, Abbestr. 2-12, 10587 Berlin, Deutschland

²ZeMA – Zentrum für Mechatronik und Automatisierungstechnik gGmbH, Eschberger Weg 46, 66121 Saarbrücken, Deutschland

³Universität des Saarlandes, Lehrstuhl für Messtechnik, Campus A5 1, 66123 Saarbrücken, Deutschland

Zusammenfassung

Prozesssensordaten erlauben nicht nur die Steuerung industrieller Prozesse, sondern auch eine Bewertung des Anlagenzustands zur Erkennung von Fehlerzuständen und Verschleiß mittels Mustererkennung durch maschinelles Lernen. Um den Einfluss von Synchronisationsfehlern innerhalb eines verteilten Sensorsystems abzuschätzen, wird hier ein System zur Zustandsüberwachung, zur Lebensdauerprognose und für End-Of-Line-Tests elektromechanischer Zylinder betrachtet. Die im Prüfstand integrierten Sensoren werden mit 10 kHz bis 1 MHz abgetastet. Betrachtet werden im Folgenden die Auswirkungen von Synchronisationsfehlern von maximal 100 ms zwischen den einzelnen Sensoren auf die Lebensdauerprognose der elektromechanischen Zylinder. Simuliert werden diese Fehler an Hand eines experimentell erfassten Rohdatensatzes durch Manipulation mit zufälligem Zeitversatz zwischen den unterschiedlichen Sensoren.

Keywords: Maschinelles Lernen, Zustandsüberwachung, multivariate Statistik, Synchronisation, Industrie 4.0

Einleitung

Globalisierte Fertigung und internationaler Handel haben durch die Digitalisierung einen technologischen Strukturwandel erfahren. Neben intelligenten Sensoren, welche nicht nur ihre Umwelt wahrnehmen, sondern auch die Messwerte gleich weiterverarbeiten und kommunizieren, kommen große Sensornetzwerke in der Fabrik der Zukunft zum Einsatz. Maschinelles Lernen (ML) ist dabei eine Schlüsseltechnologie für diese intelligenten Systeme. In der Fabrik der Zukunft stellt das „Industrial Internet of Things“ (IIoT) die Vernetzungsbasis für die Industrie 4.0 dar und dient somit der Verbesserung der betrieblichen Effektivität und Flexibilität [1]. Die stetige Weiterentwicklung intelligenter Sensorsysteme erlaubt die Automatisierung und Verbesserung komplexer Prozess- und Geschäftsentscheidungen in vielfältigen Anwendungsgebieten. Beispielsweise können Sensoren zur Bewertung des Anlagenzustandes, zur Bestimmung optimaler Wartungstermine oder zum Erkennen von Fehlerzuständen ebenso wie zur Steuerung von ganzen Produktionslinien genutzt werden. Ein grundlegendes Problem bereitet dabei die Sensordatenqualität,

welche u.a. durch Umwelteinflüsse, Sensorausfälle und – besonders in verteilten Sensornetzwerken – durch Synchronisationsprobleme zwischen den einzelnen Sensoren beschränkt ist. Auch durch Messfehler wird die Qualität der Daten herabgesetzt. Dabei erfordert das Vertrauen in ML-Algorithmen und deren Entscheidungen verlässliche Daten. Die Bewertung der Datenqualität ist daher essentiell, d.h. es wird eine metrologische Infrastruktur benötigt, welche Aussagen über die Qualität der Daten zulässt. Dieser Beitrag zeigt, wie mit Hilfe einer Software-Toolbox für statistische Analysen große Datenmengen unter dem Einfluss von künstlich erzeugten Synchronisationsfehlern ausgewertet werden und wie groß der Einfluss dieser Synchronisationsfehler auf die Ergebnisse des maschinellen Lernens sind.

Der Prüfstand zur Datenerfassung

Am verwendeten Prüfstand können Zustandsüberwachungen, Lebensdauerprognosen und End-Of-Line (EOL) Tests an elektromechanischen Zylindern (EMZ) mit Kugelumlaufspindeln durchgeführt werden. Diese Dauerhochlast- und Geschwindigkeitstests werden am Prüfstand solange durchgeführt, bis ein Fehler des EMZ auftritt. So können

relevante Sensoren und charakteristische Signalmuster für die Zustandsüberwachung identifiziert werden und eine Restlebensdauerschätzung des EMZs durchgeführt werden. Das Schema des Prüfstandes ist in Abb. 1 zu sehen. Der Aufbau besteht vereinfacht aus dem geprüften EMZ und einem Pneumatikzylinder, welcher die variable Last auf den EMZ in axialer Richtung simuliert. Die Parameter des Arbeitszyklus können mittels eines LabVIEW-GUI eingestellt werden. Ein typischer Arbeitszyklus dauert 2,8 s. Er besteht aus einer Vorhub- und einer Rückhubbewegung des Zylinders, sowie einer Wartezeit zwischen beiden Bewegungen von 150 ms. Dabei werden die Bewegungen immer mit maximaler Beschleunigung von 5 m/s^2 und annähernd maximaler Geschwindigkeit ausgeführt. Der Hubbereich des EMZs im Prüfstand liegt zwischen 100 mm und 350 mm. Die Kombination aus hoher Axialkraft (7 kN), hoher Verfahrgeschwindigkeit (200 mm/s^2) und hoher Beschleunigung (5 m/s^2) führt zu schnellem Verschleiß des EMZ. Als Fehlerkriterium für den Ausfall des EMZ wird eine zu große Abweichung zwischen Positionssoll- und Positionswert festgelegt, d.h. der Test ist beendet, sobald die spezifische Positionsgenauigkeit aufgrund erhöhter Reibung nicht mehr erfüllt ist. Um ausreichend Daten für eine umfassende Zustandsüberwachung zu sammeln, werden die folgenden Sensoren verwendet [2]:

- drei Motorstromsensoren mit einer Abtastrate von jeweils 1 MHz,
- drei Beschleunigungssensoren mit einer Abtastrate von jeweils 100 kHz, angebracht am Gleitlager, am Kugellager und an der Kolbenstange
- ein Mikrofon mit einer Abtastrate von 100 kHz

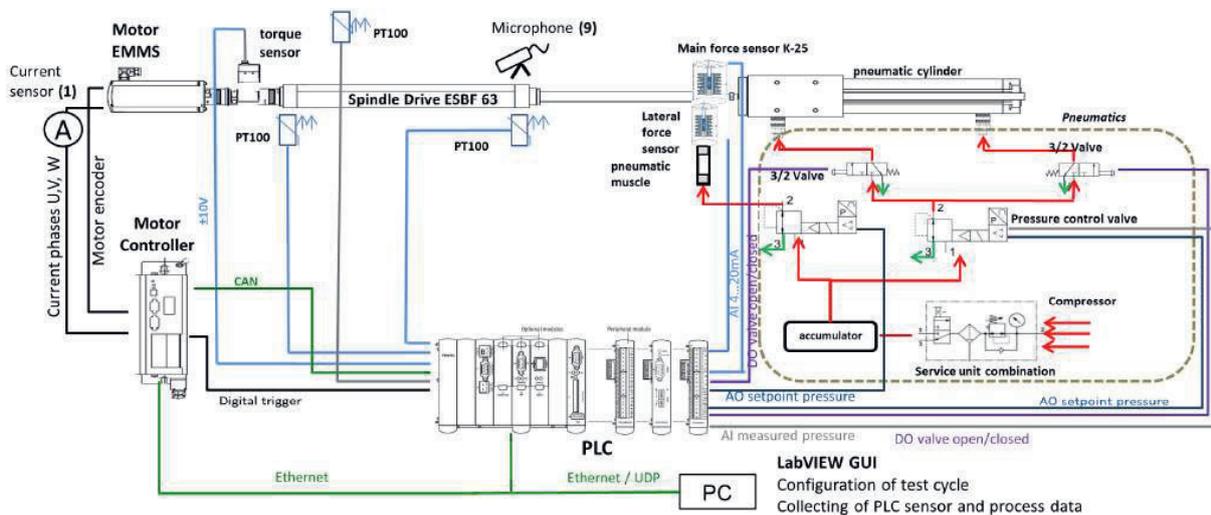


Abb. 1: Schema des Prüfstandes [4]

- vier Prozesssensoren (Axialkraft, Geschwindigkeit, pneumatischer Druck und Wirkstrom) mit einer Abtastrate von jeweils 10 kHz

Die damit erfassten Daten spiegeln die Funktionalität des EMZs und deren Abnahme während des Langzeittests wider. Für die Datenanalyse, welche im nächsten Abschnitt genauer beschrieben wird, wurden verschiedene EMZs bis zu deren Ausfall geprüft. Jeder EMZ erzeugte dabei durchschnittlich 12 TB Rohdaten.

Die Software-Toolbox zur Datenanalyse

Für die Datenanalyse wird die automatisierte Software-Toolbox verwendet, welche in [3] vorgestellt wurde. Diese kann voll automatisiert, d.h. ohne Expertenwissen und ohne detailliertes physikalisches Modell des Prozesses, verwendet werden. Nach Erfassen der Rohdaten erfolgen, wie in Abb. 2 zu sehen, die Merkmalsextraktion und -selektion sowie die Klassifikation und Evaluation. Die Merkmalsextraktion findet dabei unüberwacht statt, d.h. sie wird ohne Kenntnis der Gruppenzugehörigkeit, d.h. des aktuellen Alterungszustands, der einzelnen Arbeitszyklen durchgeführt. Aus den zyklischen Rohdaten, welche über einen konstanten Zeitraum periodisch erfasst wurden, werden formbeschreibende Merkmale generiert. Da es keine Methode gibt, die für alle Anwendungsfälle gut funktioniert, werden die Merkmale durch fünf verschiedene, sich gegenseitig ergänzende, Methoden aus verschiedenen Domänen extrahiert: Die Adaptive Lineare Approximation (ALA) unterteilt die Zyklen im Zeitbereich in annähernd lineare Abschnitte, aus denen als Merkmale Mittelwert und Steigung extrahiert werden. Bei der Hauptkomponentenanalyse (PCA) werden die Projektionen auf die Hauptkomponenten als

Merkmale verwendet. Mit Hilfe der Fouriertransformation werden bei der Methode der Besten Fourier-Koeffizienten (BFC) im Frequenzbereich die 10 % der Amplituden mit dem höchsten Betrag und die dazugehörigen Phasen als Merkmale verwendet. Die Beste Daubechies Wavelettransformation (BDW) erfolgt analog zur BFC und liefert dabei Merkmale aus dem Zeit-Frequenz-Bereich. Auch in der statistischen Verteilung der Messwerte ist Information enthalten. Diese wird mit Hilfe der ersten vier statistischen Momente (Mittelwert, Varianz, Schiefe und Wölbung) aus gleich langen Zyklusabschnitten extrahiert.

Ziel der Merkmalsextraktion ist es, Informationen in so wenigen Merkmalen wie möglich zu konzentrieren, allerdings ist die Anzahl der Merkmale nach der Merkmalsextraktion noch zu hoch. Für Big Data Anwendungen, wie z.B. die am vorher beschriebenen Prüfstand durchgeführte Restlebensdauervorhersage eines EMZs, ist die Datenreduktion nach diesem Schritt noch unzureichend. Aus diesem Grund wird im Anschluss an die Merkmalsextraktion eine Merkmalsselektion durchgeführt.

Die Merkmalsselektion ist ein überwachter Schritt, d.h. hier ist die Gruppenzugehörigkeit eines jeden Zyklus bekannt. Im konkreten Anwendungsfall bei den EMZ ist die Zielgröße die Lebensdauer mit einer Auflösung von 1 %. In diesem Schritt werden die relevantesten Merkmale bezogen auf die Klassifikationsaufgabe ausgewählt und redundante Merkmale oder Merkmale mit wenig Informationsgehalt entfernt. Auch hier liefert nicht eine einzige Methode für alle Anwendungsfälle die optimale Lösung, sodass drei verschiedene verwendet werden. Bei der Recursive Feature Elimination Support Vector Machine (RFESVM) wird eine

lineare SVM verwendet, um rekursiv die Merkmale mit dem kleinsten Beitrag zur Gruppentrennung aus der Menge aller Merkmale zu entfernen [5,6]. Der RELIEFF-Algorithmus kommt zur Anwendung, wenn die Gruppen nicht linear trennbar sind [7,8]. Die Pearson-Korrelation wird aufgrund der geringen Komplexität des Algorithmus als dritte Methode zur Merkmals(vor)selektion verwendet. Dabei werden die Merkmale nach ihrem Korrelationskoeffizienten zur Zielgröße sortiert. Dieser Koeffizient gibt an, wie groß der lineare Zusammenhang zwischen einem Merkmal und der Zielgröße ist. Neben einer Reduktion der Datenmenge wird so gleichzeitig auch eine Überanpassung vermieden, die häufig auftritt, wenn die Anzahl der Datenpunkte zur Entwicklung des Klassifikationsmodells nicht wesentlich größer als die Anzahl der Merkmale ist. Die Klassifikation läuft in zwei Schritten ab: eine weitere Dimensionsreduktion gefolgt von der eigentlichen Klassifikation. Die Dimensionsreduktion erfolgt mittels Linearer Diskriminanzanalyse (LDA). Sie führt für k Gruppen eine lineare Projektion des Merkmalsraums in einen $k - 1$ dimensionalen Unterraum durch. Dabei wird die Intraklassenvarianz, die Varianz innerhalb der Klassen, minimiert und gleichzeitig die Interklassenvarianz, die Varianz zwischen den Klassen, maximiert [9]. Die eigentliche Klassifikation erfolgt dann unter Verwendung der Mahalanobis-Distanz, siehe Gl. (1):

$$d_{Mahal}(\vec{x}) = \sqrt{(\vec{x} - \vec{m})^T S^{-1} (\vec{x} - \vec{m})}. \quad (1)$$

Dabei bezeichnet \vec{x} den Vektor der Testdaten, \vec{m} das komponentenweise arithmetische Mittel und S die Kovarianzmatrix der Gruppe. Die Mahalanobis-Distanz gibt für jeden Datenpunkt an, wie weit er vom Zentrum der Datengruppe unter Berücksichtigung der Streuung entfernt

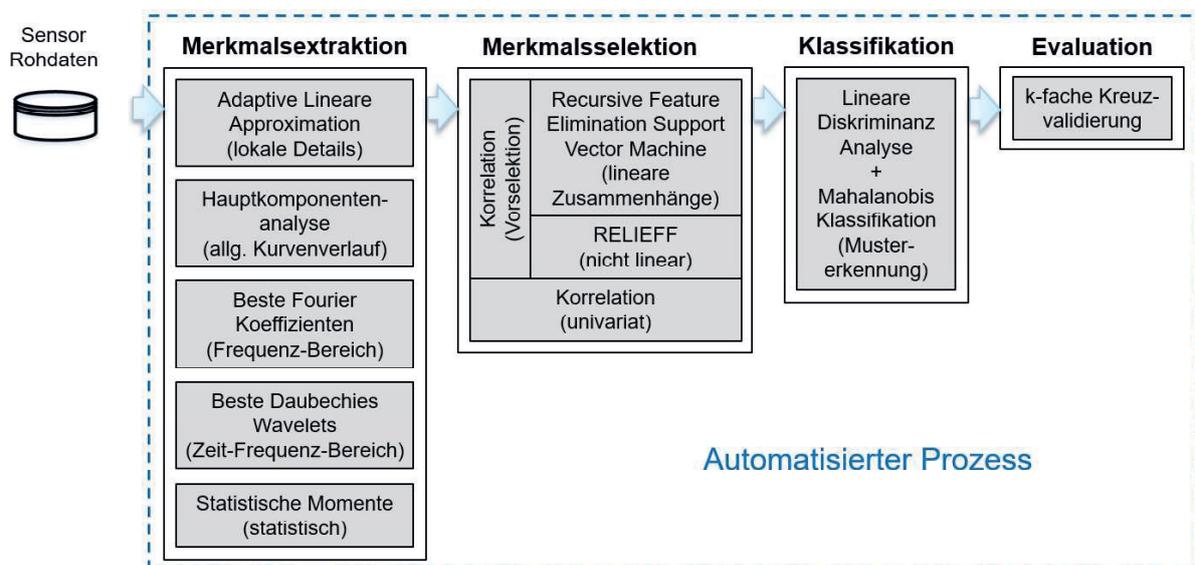


Abb. 2: Schematischer Aufbau des Methodenbaukastens

ist. Punkte gleicher Mahalanobis-Distanz von einem Zentrum bilden im zweidimensionalen Raum graphisch gesehen eine Ellipse.

Zur Evaluation wird die k -fache stratifizierte Kreuzvalidierung verwendet. Dabei wird der Datensatz in k Gruppen unterteilt, mit $k \in \mathbb{N}$. Stratifiziert bedeutet dabei, dass jede der k Teilmengen annähernd dieselbe Verteilung besitzt wie die Gesamtmenge. Gewöhnlich wird k gleich 10 gesetzt. So bildet eine Gruppe den Testdatensatz und $k - 1$ Gruppen bilden den Trainingsdatensatz.

Die verwendete Software-Toolbox vergleicht die insgesamt 15 Möglichkeiten, welche durch Kombination je einer Merkmalsextraktions- und einer Selektionsmethode entstehen. Der Kreuzvalidierungsfehler, d.h. der Prozentsatz der anhand der 10-fachen Kreuzvalidierung falsch klassifizierten Zyklen, wird automatisch für jede der 15 Möglichkeiten und jede der 10 Permutationen, welche durch die Kreuzvalidierung entstehen, errechnet. Somit ist das Finden der besten Kombination aus den Merkmalsextraktions- und Merkmalsselektionsmethoden für das jeweils aktuelle Anwendungsszenario ein vollautomatischer Prozess, welcher offline durchgeführt wird. Die eigentliche Klassifikationsaufgabe wird dann online nur noch mit der besten der 15 Möglichkeiten durchgeführt, was zu einem geringeren Rechenaufwand führt. Zusammen führen Merkmalsextraktion und Merkmalsselektion ungefähr zu einer 60-fachen Datenreduktion, d.h. die anfangs vorhandenen 12 TB an Rohdaten werden auf einen Merkmalsdatensatz von ca. 200 MB reduziert.

Synchronisationsprobleme und deren Auswirkungen

Zur Analyse der Auswirkungen von Synchronisationsproblemen zwischen den am Prüfstand verbauten Sensoren und deren Auswirkungen auf die Lebensdauerprognose am Beispiel elektromechanischer Zylinder wird ein Langzeittest mit einer Dauer von 20,4 Tagen und über 600.000 Zyklen herangezogen. Für die im vorherigen Abschnitt vorgestellte Software-Toolbox zum maschinellen Lernen wird je Arbeitszyklus nur eine Sekunde während der Gleichlaufphase des Rückhubes verwendet. In dieser Zeitspanne ist, wie in Abb. 3 zu sehen, die Geschwindigkeit konstant und die Belastung am größten, da dort gegen eine konstante Last gezogen wird. Simuliert wurden die Synchronisationsfehler durch Manipulation des Rohdatensatzes mit zufälligem Zeitversatz zwischen den unterschiedlichen Sensoren. Der zufällige Zeitversatz beträgt dabei maximal 100 ms, um sicherzustellen, dass für alle Sensoren nur Daten aus der Gleichlaufphase zur Auswertung herangezogen werden. Als

Selektor wird bei allen Auswertungen die Pearson-Korrelation verwendet.

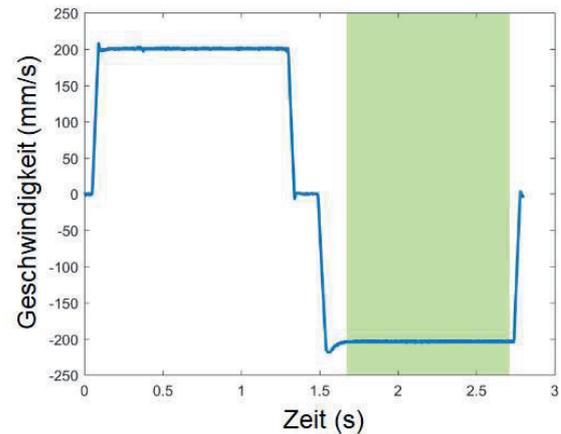


Abb. 3: Arbeitszyklus bestehend aus Vorhub, Wartezeit und Rückhub, sowie der Ausschnitt (grün), welcher für die Auswertung der Lebensdauer verwendet wird

Bei den Daten ohne Zeitverschiebung werden die besten Merkmale, wie in Abb. 4 zu sehen, mit BFC aus dem Frequenzbereich extrahiert. Der geringste Kreuzvalidierungsfehler mit 8,72 % Fehlklassifikation tritt bei der Verwendung von 493 Merkmalen auf, mit 100 Merkmalen liegt der Kreuzvalidierungsfehler bei 11,33 %.

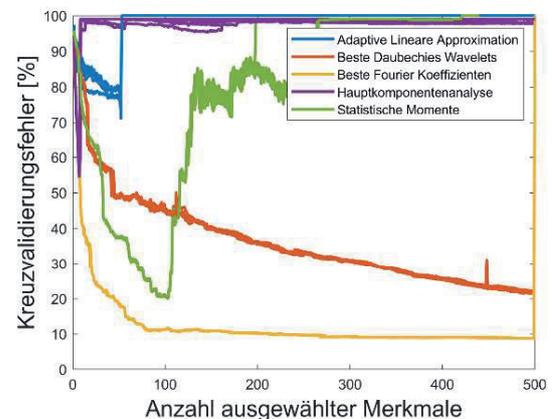


Abb. 4: Kreuzvalidierungsfehler über die Anzahl der Merkmale beim Rohdatensatz mit Verwendung der Pearson-Korrelation als Selektor

Die Klassifikationsfehler treten dabei häufig an Gruppengrenzen auf. Durch eine Mittelung über 15 Minuten (321 Zyklen) mittels Mehrheitsfilter werden diese Klassifikationsfehler entfernt, sodass danach nur noch sehr wenige Fehler am Ende der Laufzeit verbleiben, wie in Abb. 5 gezeigt. Zusätzlich wird in Abb. 6 für BFC als Merkmalsextraktor gezeigt, welche Sensoren bei der Lebensdauerprognose am wichtigsten sind. Dabei ist deutlich zu erkennen, dass 58 %

der Merkmale aus den Daten des Mikrofons stammen, wovon wiederum 99 % Amplituden sind. Diese Informationen werden bei der Erzeugung einiger künstlicher Zeitversätze berücksichtigt.

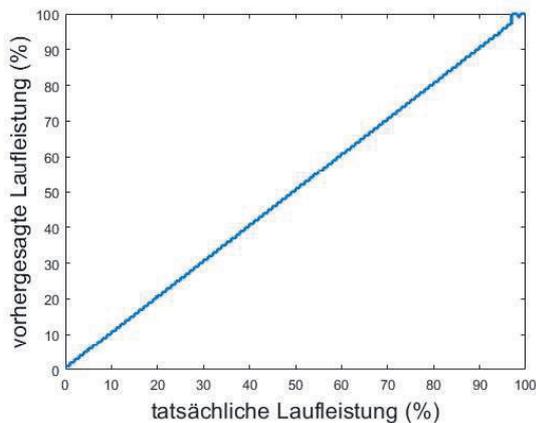


Abb. 5: Vorhergesagte über tatsächliche Laufleistung bei einer Mittelung über 15 Minuten

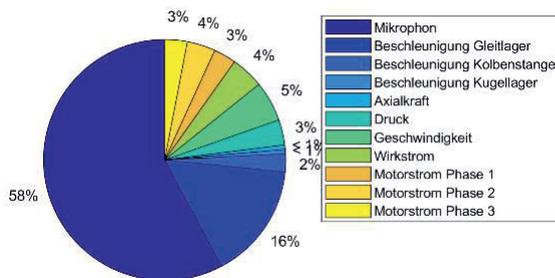


Abb. 6: Prozentsatz der besten Merkmale je Sensor, ausgewählt durch Pearson-Korrelation

Zunächst werden Zeitversätze von maximal 0,1 ms je Sensor bis zu maximal 100 ms je Sensor betrachtet. Dabei ist ein Anstieg des

minimalen Klassifikationsfehlers bei steigendem Zeitversatz zu erkennen (siehe Tab. 1). Da die Ergebnisse fast äquivalent zu denen mit den Rohdaten sind, werden diese hier nicht explizit gezeigt. BFC ist immer die beste Extraktionsmethode, die Änderung des Klassifikationsfehlers liegt im einstelligen Bereich und über 50 % der selektierten Merkmale stammen aus den Daten des Mikrofons.

Daher wird im Folgenden nur ein Zeitversatz von maximal ± 100 ms betrachtet, um die die Daten jedes einzelnen Sensors zufällig verschoben werden. Dieser Zeitversatz ist zum einen der, welcher bei der Zykluslänge von 2,8 s und Betrachten des Rückhubes maximal möglich ist, zum anderen liefert dieser Versatz die schlechteste Klassifikationsrate. Wie in Abb. 7 zu sehen, werden die besten Merkmale wie beim Rohdatensatz mit Hilfe der BFC generiert. Allerdings liegt der minimale Klassifikationsfehler nun bei 19,3 % und damit deutlich schlechter als bei Verwendung der Rohdaten.

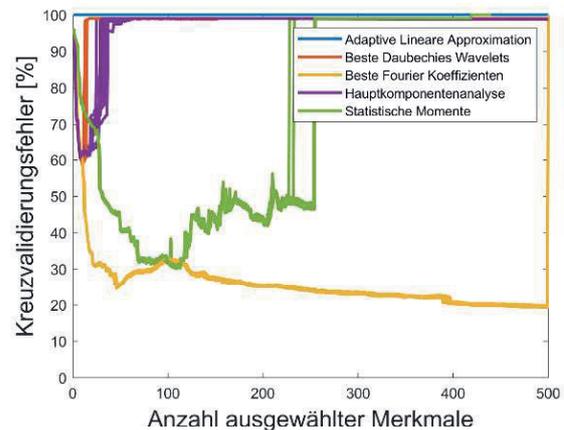


Abb. 7: Kreuzvalidierungsfehler über die Anzahl der Merkmale bei maximal ± 100 ms Zeitversatz und Pearson-Korrelation als Selektor

Tab. 1: Klassifikationsfehler der verschiedenen Zeitversätze mit BFC als Merkmalsextrator

Zeitversatz	Sensoren mit Zeitversatz	min. Fehler	selektierte Merkmale (davon Amplituden)	Merkmale aus Mikrofon-daten	Fehler bei 100 selektierten Merkmalen
ohne	-	8,72 %	493 (90 %)	58 %	11,33 %
max. $\pm 0,1$ ms	alle	9,11 %	497 (93 %)	60 %	11,05 %
max. $\pm 0,5$ ms	alle	9,43 %	498 (96 %)	63 %	11,84 %
max. ± 1 ms	alle	9,73 %	491 (97 %)	64 %	12,80 %
max. ± 10 ms	alle	10,10 %	496 (100 %)	65 %	13,61 %
max. ± 50 ms	alle	13,17 %	497 (100 %)	65 %	20,87 %
max. ± 100 ms	alle	19,30 %	499 (100 %)	66 %	32,55 %
konst. +1 ms	nur Mikrofon	8,88 %	498 (90 %)	57 %	11,66 %
konst. +100 ms	nur Mikrofon	8,59 %	499 (90 %)	58 %	11,14 %
max. +100 ms	nur Mikrofon	8,78 %	495 (90 %)	57 %	11,74 %

Die mögliche Ursache für die deutliche Verschlechterung der Klassifikationsrate liegt vermutlich darin, dass nun nicht mehr nur Daten aus der Gleichlaufphase des Rückhubes verwendet werden, sondern auch Daten aus der Beschleunigungs- bzw. Verzögerungsphase des Rückhubes mit in die Auswertung einfließen. Mittels Mehrheitsfilter werden einige Klassifikationsfehler entfernt, allerdings verbleiben während der letzten 20 % der Lebensdauer des EMZs deutliche Klassifikationsfehler, wie in Abb. 9 dargestellt.

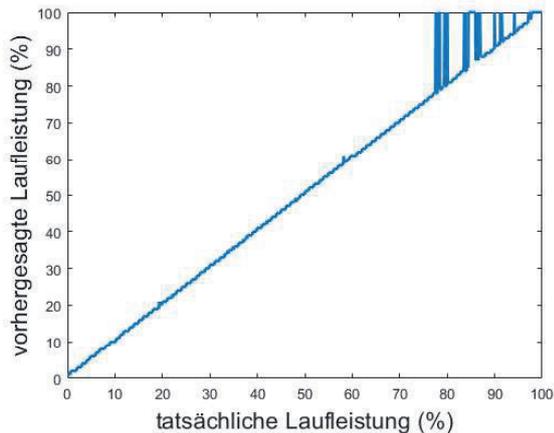


Abb. 8: Vorhergesagte über tatsächliche Laufleistung bei einer Mittelung über 15 Minuten für den manipulierten Datensatz mit max. ± 100 ms Zeitversatz zwischen den Sensoren

Abschließend werden die Klassifikationsfehler für die Zeitversätze von 0,1 ms bis 100 ms zwischen allen 11 Sensoren betrachtet. Diese sind in Abb. 9 dargestellt.

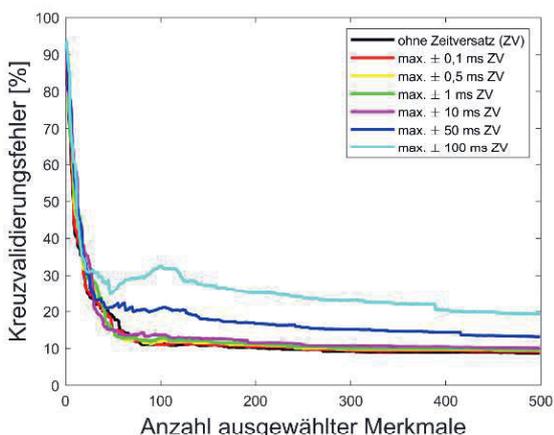


Abb. 9: Kreuzvalidierungsfehler über die Anzahl der Merkmale für unterschiedliche simulierte Synchronisationsfehler

Auch hier ist deutlich zu erkennen, dass ein minimaler Zeitversatz nur eine geringe

Auswirkung auf das Ergebnis der Lebensdauerprognose eines EMZs hat, wohingegen größere Zeitversätze die Ergebnisse deutlich verschlechtern.

Fazit und Ausblick

Wie gezeigt, wirken sich minimale Synchronisationsfehler zwischen den einzelnen Sensoren nur sehr gering auf die Klassifikationsraten aus. Ein Zeitversatz nur für die Daten des Mikrofons hat ebenfalls nur sehr geringe Auswirkungen auf die Ergebnisse der Lebensdauerprognose von EMZs, da aus den Daten des Mikrofons primär Amplituden verwendet werden. Die durchgeführte Analyse gibt somit wichtige Hinweise für die Auslegung verteilter Messsysteme speziell im Hinblick auf die erforderliche Synchronisation zwischen den Sensoren. Im weiteren Verlauf des Projektes „Metrology for the Factory of the Future“ (Met4FoF) werden mathematische Modelle zur Berücksichtigung von metrologischen Informationen entwickelt. Damit werden die Methoden der Software-Toolbox erweitert, um Messunsicherheiten bei der Vorhersage der Restlebensdauer von EMZ berücksichtigen zu können. Ein weiterer Schritt im Projekt betrifft die Klassifikation innerhalb der Software-Toolbox. Dabei wird die Robustheit der LDA als Klassifikator bei Redundanz der Merkmale überprüft. Eine Frage für die weitere Forschung ist dabei, wie lange sich die Qualität der Ergebnisse der LDA verbessert und ab wann sie sich plötzlich verschlechtert, da die Kovarianzmatrix singulär wird, d.h. ihre Determinante verschwindet.

Danksagungen

Ein Teil dieser Arbeit wurde durch das EU-weite Forschungsprogramm EMPIR finanziert, welches von der EU, den EMPIR-Mitgliedsländern und von Horizont 2020, dem Rahmenprogramm der Europäischen Union für Forschung und Innovation, kofinanziert wird. Der ZeMA-Prüfstand wurde im Rahmen des Forschungsprojekts MoSeS-Pro entwickelt, welches vom Bundesministerium für Bildung und Forschung im Aufruf Sensorbasierte Elektroniksysteme für Anwendungen für Industrie 4.0 (SElekt I4.0), Förderkennzeichen 16ES0419K, im Rahmen der deutschen Hightech-Strategie gefördert wurde.

Literaturnachweis

- [1] S. Eichstädt, "Publishable Summary for 17IND12 Met4FoF Metrology for the Factory of the Future," 2018.
- [2] T. Schneider, N. Helwig, S. Klein, and A. Schütze, "Influence of Sensor Network Sampling Rate on Multivariate Statistical Condition Monitoring of Industrial Machines and

- Processes," *Proceedings*, vol. 2, no. 13, p. 781, Dec. 2018; doi: 10.3390/proceedings2130781
- [3] T. Schneider, N. Helwig, and A. Schütze, "Industrial condition monitoring with smart sensors using automated feature extraction and selection," *Meas. Sci. Technol.*, vol. 29, no. 9, 2018; doi: 10.1088/1361-6501/aad1d4
- [4] N. Helwig, T. Schneider, and A. Schütze, "MoSeS-Pro: Modular sensor systems for real time process control and smart condition monitoring using XMR-technology," *Proc. 14th Symp. Magnetoresistive Sensors Magn. Syst.*, 2017.
- [5] I. Guyon, "An introduction to variable and feature selection," *J. Mach. Learn. Res.*, vol. 3, pp. 1157--1182, 2003; doi: 10.1162/153244303322753616
- [6] A. Rakotomamonjy, "Variable Selection Using SVM-based Criteria," *J. Mach. Learn. Res.*, vol. 3, pp. 1357--1370, 2003; doi: 10.1162/153244303322753706
- [7] I. Kononenko and S. J. Hong, "Attribute selection for modelling," *Futur. Gener. Comput. Syst.*, vol. 13, no. 2-3, pp. 181-195, Nov. 1997; doi: 10.1016/S0167-739X(97)81974-7
- [8] M. Robnik-Šikonja and I. Kononenko, "Theoretical and Empirical Analysis of ReliefF and RReliefF," *Mach. Learn.*, vol. 53, no. 1, pp. 23-69, 2003; doi: 10.1023/A:1025667309714
- [9] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*, 2. ed. New York: Wiley, 2001.