

# Eine Methode zur erklärbaren Merkmalsextraktion aus dem Zeit- und Frequenzbereich für Condition Monitoring

*Christian Fuchs, Steffen Klein, Julian Schauer, Andreas Schütze, Tizian Schneider*  
 Universität des Saarlandes, Lehrstuhl für Messtechnik, Universität Campus  
 Gebäude A5.1, 66123 Saarbrücken, Deutschland  
 c.fuchs@imt.uni-saarland.de

## Zusammenfassung

Zu neuronalen Netzen bieten klassische maschinelle Lernmethoden eine Alternative zur robusten Auswertung von industriellen Messdaten und deren Verständnis. Merkmalsextraktionsmethoden dienen dabei zum einen der Reduktion der Datenmenge, zum anderen können sie genutzt werden, um Zusammenhänge zwischen Merkmalen und physikalischen Größen zu plausibilisieren.

Hier wird der Time Frequency Extractor (TFEx) vorgestellt, der Signale sowohl im Zeit- und Frequenzbereich analysiert, sowie sie in Bänder unterteilt, deren Strukturen a priori bekannt sind. Aus diesen Bändern werden Merkmale extrahiert und danach werden die besten Merkmale durch eine Ranking- oder Selektionsmethode bestimmt. Mit Hilfe der bekannten Unterteilungsstruktur und des Merkmalarankings kann rückverfolgt werden, aus welchen Signalbereichen und welcher Domäne (Zeit oder Frequenz) die selektierten Merkmale stammen. Es ist dadurch zum Beispiel nachvollziehbar, aus welchem Zeitsegment und aus welchem Frequenzband das höchst selektierte Merkmal stammt und welche Art von Merkmal dort berechnet wurde. Hier wurden zwei Datenbeispiele herangezogen. Beim ersten Datensatz wurde ein trivialer Zusammenhang zwischen Merkmal und Vorhersage festgestellt und beim zweiten Datensatz wurde ein Korrelationsproblem in den Daten identifiziert.

**Keywords:** Condition Monitoring, Feature Extraction, Explainable AI, Sensor Fusion.

## Einleitung

Maschinelles Lernen wird in den meisten Fällen direkt mit neuronalen Netzen in Verbindung gebracht. Diese sind zwar universell, werden aber häufig als Black Box gesehen [1]. Es gibt verstärkte Bemühungen, die Zwischenschritte des maschinellen Lernens zu visualisieren und zu plausibilisieren [2, 3].

Ein alternativer Ansatz zu Deep Learning ist Feature Extraction, Selection, Classification / Regression (FESC/R, [4]). Dieser bietet die Möglichkeit, physikalisch interpretierbare Merkmale zu verwenden.

Bei industriellen Messdaten ergeben sich außerdem statistische Abhängigkeiten z.B. weil alle Trainingsdaten aus Kostengründen an derselben Maschine aufgezeichnet wurden. Dadurch kann die Übertragbarkeit der Modelle auf andere Maschinen nicht statistisch gezeigt werden, und es braucht eine physikalische Interpretation des gelernten Modells, um dessen physikalische Sinnhaftigkeit zu plausibilisieren.

Merkmalsextraktoren beschränken sich häufig auf Merkmale entweder aus der Zeit- oder der Frequenzdomäne. Beispiele dafür sind Statistische Momente [5] oder die Hauptkomponentenanalyse (Principal Component Analysis, PCA [6]). In diesem Paper wird der Time Frequency

Extractor (TFEx) vorgestellt, der relevante Merkmale sowohl aus dem Zeit- als auch dem Frequenzbereich extrahiert.

Durch Benchmarks verschiedener Merkmalsextraktionsmethoden stellte sich heraus, dass der TFEx sich für ein breites Feld von industriellen Anwendungsfällen eignet [7]. Gleichzeitig bietet er in Kombination mit FESC/R Möglichkeiten im Bereich der Merkmal-Plausibilisierung und ist in der Lage robuste Ergebnisse zu liefern [8]. Der TFEx ist automatisiert anwendbar [9].

Neben der vollständigen Beschreibung der Methode stehen hier die Möglichkeiten zur Merkmal-Plausibilisierung als Werkzeug für Explainable AI im Vordergrund.

## Funktionsweise Extraktor

In diesem Abschnitt wird die Funktionsweise des TFEx beschrieben sowie die Wahl der Merkmale begründet.

Die beiden wesentlichen Elemente des TFEx sind die Segmentierung, sowie die gleichzeitige Analyse von Zeit- und Frequenzdomäne. Dies ist in Abbildung 1 anhand eines Beispielsignals dargestellt. Der TFEx bildet Segmente im Zeit- und Frequenzbereich. Die Rohdaten werden im Zeitbereich in äquidistante, linear unterteilte Segmente aufgeteilt, die wiederum durch Fouri-

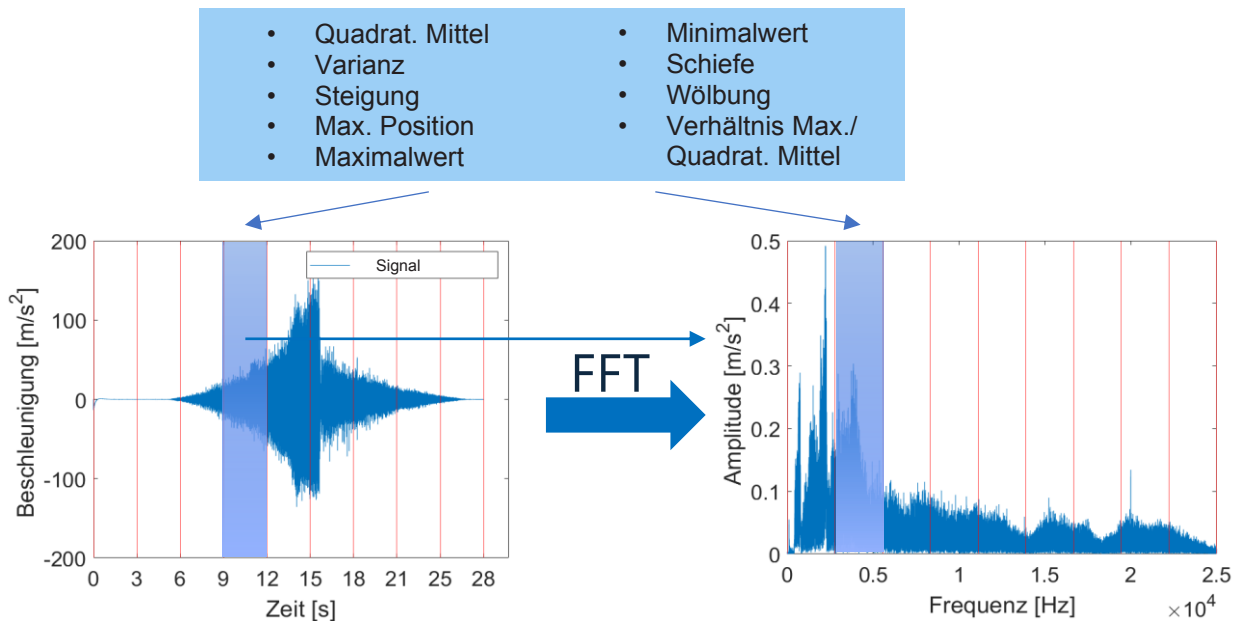


Abb. 1: Extraktionsmuster des TFEEx: Neun Merkmale aus z.B. zehn Zeit- und zehn Frequenzsegmenten, linear und äquidistant unterteilt. Blaue Markierungen: Beispiel Herkunft Merkmal.

er-Transformation in den Frequenzbereich (Amplitudenspektrum) überführt werden. Alle resultierenden Frequenzspektren werden wiederum linear und äquidistant unterteilt. Zusätzlich werden alle Spektren und der vollständige Zeitbereich auch ohne Unterteilung verwendet. Für alle Zeit- und Frequenzsegmente werden die in Abb. 1 genannten statistischen und formbeschreibenden Merkmale berechnet. Die Anzahl der Zeitsegmente und Frequenzbänder lässt sich an den jeweiligen Anwendungsfall anpassen. Im gezeigten Beispiel wurden zehn Zeitsegmente und zehn Frequenzbänder gewählt.

Die Wahl einer linearen und äquidistanten Unterteilung begründet sich zum einen durch die einfache Parametrisierung. Zum anderen sind bei industriellen Messsignalen auch hochfrequente Signalanteile relevant [10], welche mit linearen Bändern detaillierter unterteilt werden als mit der weit verbreiteten logarithmischen Unterteilung [11].

### Hyperparameter

Die wichtigsten Hyperparameter des TFEEx sind:

- Anzahl Zeitsegmente
- Anzahl Frequenzsegmente pro Zeitsegment

Die Anzahl der Segmente kann jeweils als Hyperparameter für die Zeit- und Frequenzdomäne gewählt werden.

Zur Automatisierbarkeit entsteht der Bedarf nach breit nutzbaren Default Werten, die zur Generierung eines universellen Merkmalssets beitragen.

### Anzahl Zeitsegmente

Bei der Wahl der Anzahl der Zeitsegmente ist entscheidend, ob das Signal zeitdynamisch oder quasistationär ist. Während quasistationäre Signal mit wenigen Segmenten (eins bis fünf) bereits gut beschrieben werden können, braucht es bei zunehmender zeitlicher Dynamik mehr Segmente (z.B. zehn).

Ohne Prozesswissen werden für die automatisierte Nutzung fünf Zeitsegmente als Ausgangspunkt empfohlen.

### Anzahl Frequenzsegmente

Die Einteilung des Frequenzbereichs ist von der Abtastrate abhängig, da die Anzahl der Frequenzbänder deren Bandbreite beeinflusst. Daher sollten kleinere Abtastraten mit einer geringeren Anzahl an Frequenzbändern einhergehen. Dennoch sollte man v.a. bei hohen Abtastraten die Anzahl der resultierenden Merkmale und die mögliche Redundanz im Auge behalten. Ohne Prozesswissen werden für die automatisierte Nutzung zehn Frequenzsegmente als Ausgangspunkt empfohlen.

### Extrahierte Merkmale

Aus jedem der Segmente und Bänder werden nun die in Abb. 1 gelisteten neun Merkmale extrahiert. Sie beschreiben das Signal im jeweiligen Segment in seiner Form. Der quadratische Mittelwert (RMS), Varianz, Schiefe und Wölbung werden verwendet, um die Verteilung der Messdaten im jeweiligen Segment zu

beschreiben. Zusätzlich zu den statistischen Momenten werden Maxima und Minima untersucht, welche vor allem bei kalibrierten Sensoren viel Information enthalten können. Außerdem werden die Position des Maximums und dessen Verhältnis zum RMS-Wert extrahiert, z.B. um die Position von Frequenzpeaks und deren Ausprägung zu erfassen. Zusätzlich wird die Steigung betrachtet, welche z.B. einen innerhalb eines Segments neu auftretenden Offset erkennen könnte.

### Anzahl Merkmale

Die Anzahl der insgesamt extrahierten Merkmale berechnet sich entsprechend der linearen Segmentierung folgendermaßen:

$$nFeat = nFeatSeg * [nSegT + 1 + (nSegT + 1) * (nSegF + 1)] \quad (1)$$

Dabei ist  $nFeatSeg$  die Anzahl der Merkmale pro Segment (hier: neun, vgl. Abb. 1);  $nSegT$  ist die Anzahl der Zeitsegmente;  $nSegF$  die Anzahl der Frequenzbänder; und  $nFeat$  die resultierende Gesamtanzahl an extrahierten Merkmalen. Die Additionen um eins erklären sich jeweils durch die zusätzliche Verwendung des vollständigen Zeitbereichs und der vollständigen Amplitudenspektren.

### Datensätze

Um die Möglichkeiten der Methode zu visualisieren, werden beispielhaft Datensätze gewählt, anhand derer die Leistungsfähigkeit und Plausibilisierbarkeit gezeigt werden.

#### Hill-Valley with noise

Der erste Datensatz ist der Open Source Datensatz „Hill-Valley“ [12], vgl. Abb. 2.

Bei diesem simulierten Datensatz geht es darum, zu erkennen, ob die Daten einen „Hügel“




Abb. 2: Rohdaten Hill-Valley Datensatz, Beispiel erste Messung mit dem Label Valley („Tal“).

oder ein „Tal“ formen. Jedes Datensample besteht dabei aus je 100 Datenpunkten, die mit zusätzlichem Rauschen beaufschlagt wurden.

Der Plot zeigt, dass dieser Effekt mit dem bloßen Auge erkennbar ist. Es ist aber nicht festgelegt, zu welchem Zeitpunkt diese Hügel und Täler auftreten, was die automatisierte Klassifikation erschwert.

Dieser Datensatz eignet sich zur Demonstration des Extraktors, da er strukturell einen Sensor in einem Arbeitszyklus darstellen könnte. Des Weiteren ist der Datensatz weit verbreitet und anschaulich, wodurch die Ausführungen nachvollziehbar sind.

#### Hydraulik (Detektion freier Luft in Öl)

Als zweites Beispiel wurde eine Messung an einem Hydraulik-Prüfstand (Schwingungsanalyse, [13]-[16]) mit Beschleunigungssensoren verwendet. Es wurde Luft in das Öl geblasen. Danach wurden Daten bei verschiedenen Luftgehalt- und Normalzuständen mit zwei dreiaxigen Beschleunigungssensoren („Acc 1“ und „Acc 2“) aufgezeichnet (Abb. 3). Der Prüfstand simuliert im Betrieb eine hydraulische Presse, die 10s in die Druckbegrenzung läuft und danach jeweils 10s lang unterschiedliche Druckniveaus hält. Die Sensoren wurden jeweils an der Antriebseinheit der Primär- und der Sekundärpumpe befestigt. Die Abtastrate der Beschleunigungssensoren beträgt 8192 Hz.

Diese Daten wurden ausgewählt, da sie sowohl einen zeitlich unterteilten Verlauf (Druckzyklus) als auch frequenzspezifische Informationen wie Resonanzfrequenzen aufweisen [17].

#### Methodik Merkmalsinterpretation

Zunächst werden Merkmale mittels TFE<sub>x</sub> berechnet und mit einer geeigneten Ranking-Methode nach Relevanz sortiert. Abb. 4 zeigt das höchst selektierte Merkmal nach der Zielgröße sortiert. Die Skalierung ist hier für beide gültig.




Abb. 3: Rohdaten Hydraulik Datensatz, Beispiel erste Messung X-Achse von „Acc 1“




Abb. 4: Höchst selektiertes Merkmal, sortiert und geplottet über die Zielgröße (hier: Hill = 1, Valley = 0).

### Merkmals-Ranking / Plausibilisierung

Als Ranking-Methode wird hier „Maximum Relevance, Minimum Redundancy“ (MRMR, [18]) gewählt, da diese Methode bei der Sortierung die potentielle Redundanz durch Merkmale aus unterschiedlichen Segmenten berücksichtigt.

Wendet man die beschriebene Methodik auf den Hill-Valley Datensatz an, kristallisiert sich die Wölbung über den vollständigen Zeitbereich als bestes Merkmal heraus (vgl. Abb. 4).

Es ist klar zu sehen, dass alle Hügel rechtschief (Schiefe > 0) und alle Täler linksschief (Schiefe < 0) sind. Dies ist einfach zu erklären, da die Mehrzahl der Datenpunkte nah an der Grundlinie liegen und Täler für negative Ausreißer bzw. Hügel für positive Ausreißer sorgen und so die Schiefe der Verteilung beeinflussen. Damit hat die Methode für diesen Datensatz ein klar erklärbares Merkmal gefunden, welches allein stehend eine perfekte Klassifizierung von Tälern und Hügeln erlaubt.

### Multisensor-Methode

Für den Hydraulik-Datensatz wird die gleiche Methodik angewandt wie vorher bereits auf die Hill Valley Daten. Zusätzlich wird hier eine Multisensor-Methode angewandt, mit Selektion mehrerer Merkmale, die zur Auswertung beitragen. Für Datensätze mit mehreren Sensoren werden die Merkmale für jeden Sensor einzeln berechnet und zum Ranking in einen Merkmalspool zusammengefasst. Dadurch können alle sechs Kanäle (zwei Sensoren mit je drei Achsen) berücksichtigt werden.

Das höchst selektierte Merkmal wird wieder aufsteigend über der Zielgröße aufgetragen und individuell skaliert, vgl. Abb. 6. Hierbei entspricht die Reihenfolge der aufgetragenen Kurven dem zeitlichen Ablauf der Experimente.

Als Hyperparameter für den TFE<sub>x</sub> werden die empfohlenen fünf Zeitsegmente und zehn Fre-

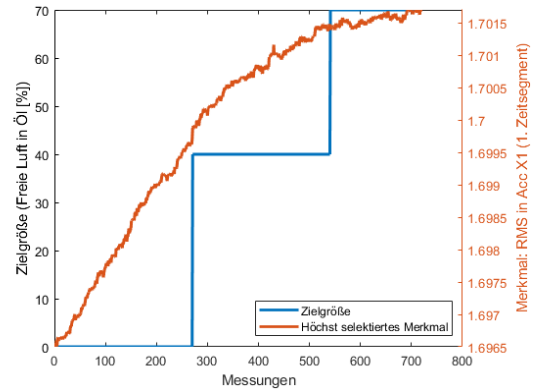


Abb. 5: Höchst selektiertes Merkmal, sortiert und geplottet über die Zielgröße (hier: Freie Luft in Öl / Lufteintrag [%]).

quenzabschnitte gewählt. Hier wird das beste Merkmal aus dem ersten von fünf Zeitsegmenten der X-Achse von „Acc 1“ („Acc X1“, vgl. Abbildung 6) ermittelt und es handelt sich um den RMS Wert aller Messungen in diesem Zeitsegment.

### Problemidentifikation

Auch für diesen Datensatz ist eine Korrelation des besten Merkmals zur Zielgröße mit dem bloßen Auge erkennbar, was die Klassifizierung ermöglichen kann. Es ist allerdings auffällig, dass die Kurve nicht stufenweise verläuft, sondern kontinuierlich.

Außerdem ist aus dem Design of Experiment (DoE) bekannt, dass das Merkmal und die Zielgröße in dieser Darstellung exakt in der Reihenfolge der Experimente aufgetragen ist. Betrachtet man den Wertebereich des unskalierten Merkmals genauer, stellt man fest, dass es sich um eine sehr geringe Steigerung des RMS von 1 % über den zeitlichen Verlauf der Messungen handelt. Hierbei könnte es sich um verstärkte Vibrationen durch erhöhte Öltemperaturen im Laufe der Messungen bei steigender Betriebstemperatur handeln.




Abb. 6: Bestes Merkmal aus markiertem Zeitbereich („RMS T“ aus „Acc X1“, 1. Exp.).

Zusätzlich zum besten Merkmal enthalten auch die sonstigen selektierten Merkmale Informationen, um die Vorhersage zu präzisieren. Es gilt dabei, den Sweetspot [4] zur Anzahl der Merkmale zu ermitteln, der zum besten Endergebnis führt. Dazu können z.B. die Bayes-Optimierung oder Parameter-Sweeps verwendet werden. Anhand stufenweiser Parameter-Sweeps wurde hier mit 250 Merkmalen das beste Ergebnis erreicht (vgl. Abb. 12).

### Multisensorverteilung

Für die insgesamt sechs Kanäle (zwei Sensoren mit je drei Kanälen) wird ein Pie Chart generiert, das anzeigt (Abb. 7), wie viel Prozent der 250 selektierten Merkmale aus den jeweiligen Sensorkanälen stammen.




Abb. 7: Anteile der Sensorkanäle an den 250 selektierten Merkmalen.

Des Weiteren wird von jedem Sensorkanal eine Übersicht erstellt, um zu erkennen aus welchen Signalbereichen wie viele Merkmale stammen. Dies wird hier anhand des mit 26% meist verwendeten Kanals „Acc X1“ durchgeführt. Dabei entstehen insgesamt drei Plots:

1. Zeitintervalle der Zeitmerkmale
2. Zeitintervalle der Frequenzmerkmale
3. Frequenzbänder der Frequenzmerkmale

Zunächst werden also die Zeitintervalle der Zeitmerkmale aufgetragen (Abb. 8).




Abb. 8: Anzahl der Zeitmerkmale des Sensorkanals „Acc X1“ pro Zeitsegment.

Dort ist zu erkennen, dass je ein Zeitmerkmal aus dem zweiten und fünften Zeitsegment sowie zwei Zeitmerkmale aus dem vierten Zeitsegment stammen.

Als Nächstes werden die Frequenzmerkmale betrachtet. Da der TFEx die Spektren auch über die einzelnen Zeitsegmente bildet, werden diese als Erstes identifiziert (Abb. 9). Dort ist direkt zu erkennen, dass zehn Frequenzmerkmale aus dem gesamten Zeitbereich stammen. Man beachte dabei, dass Merkmale über den gesamten Bereich (Start der Trennstreife) als Offset zu betrachten sind, da sie über das ganze Signal bereits als Merkmale zählen.

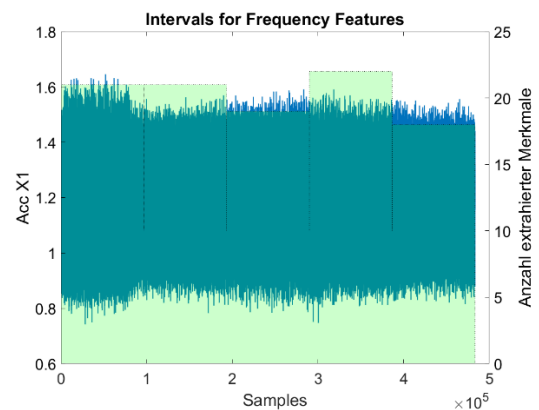


Abb. 9: Anzahl der Frequenzmerkmale des Kanals „Acc X1“ pro Zeitsegment.

Dadurch ergibt sich außerdem, dass elf Frequenzmerkmale aus den ersten beiden Zeitsegmenten stammen; neun aus dem dritten; zwölf aus dem vierten sowie acht Frequenzmerkmale aus dem fünften Zeitsegment. Damit sind es insgesamt vier Zeitmerkmale und 61 Frequenzmerkmale, die aus dem Sensorkanal „Acc X1“ stammen ( $65/250 = 26\%$ , vgl. Abb. 7).

Als letztes wird aufgetragen, aus welchen Frequenzbändern diese vier Merkmale stammen (Abb. 10).

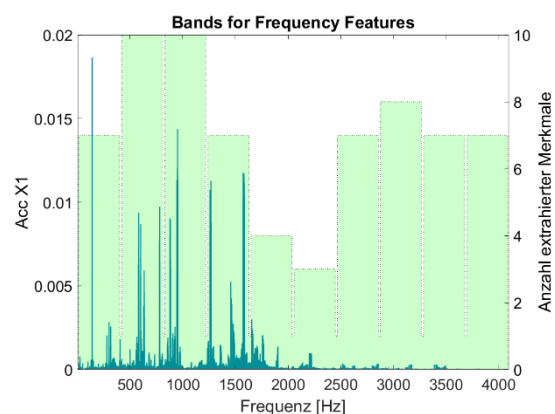


Abb. 10: Anzahl aller Frequenzmerkmale des Kanals „Acc X1“ pro Frequenzband.

Im Detail zeigt Abbildung 10, dass ein Frequenzmerkmal aus dem gesamten Frequenzspektrum stammt, sechs weitere je aus dem ersten, vierten, siebten, neunten und zehnten Frequenzband; neun je aus dem zweiten und dritten; drei aus dem fünften; zwei aus dem sechsten sowie sieben Frequenzmerkmale aus dem achten Frequenzband. Auch hier ist zu beachten, dass Merkmale aus dem gesamten Frequenzbereich als Offset zu betrachten sind. Die Summe der Frequenzmerkmale muss auch hier 61 ergeben, da jedes einzelne den zuvor ermittelten Zeitsegmenten entstammt.

Aus physikalischer Sicht ist hier auffällig, dass viele Merkmale aus dem Frequenzbereich zw. 500 Hz und 1600 Hz stammen, in welchen einige Frequenzpeaks zu verorten sind. Davon können einige mit Resonanzfrequenzen des Messaufbaus in Verbindung gebracht werden, welche bei Voruntersuchungen festgestellt wurden [17]. Ein Beispiel hierfür sind die Kühllamellen des Primärtriebs, deren Eigenfrequenzen u.a. bei 585 Hz und 1585 Hz auftraten.

## Ergebnisse Klassifikation

Um möglichst kurz gefasst zu verifizieren, dass mit den gezeigten Merkmalen auch eine Klassifizierung möglich ist, werden die selektierten Merkmale mit einer Linearen Diskriminanzanalyse [19] mit nachfolgender Berechnung der Mahalanobis Distanz [20] (LDAMahal) ausgewertet. Außerdem werden alle Ergebnisse 3-fach zufällig kreuzvalidiert (3-fold cv), um die statistische Robustheit zu prüfen.

### Hill Valley (with Noise)

Im Falle des Hill Valley Datensatz konnte mit den erlangten Merkmalen ein Klassifikationsfehler von 0% bei der 3-fach Kreuzvalidierung erreicht werden. Da das Merkmal physikalisch unumstritten eine klare Trennung der beiden Klassen zulässt, resultiert dies in einer perfekten Konfusionsmatrix, die in Abb. 11 dargestellt ist. Dieses Ergebnis ist aufgrund des erklärbaren Merkmals plausibel.




Abb. 11: Hill-Valley-Datensatz, Vorhersage der Klassifikation per LDA und Mahalanobis-Distanz mit 3-fold cv.

## Hydraulik Ölverschmutzung

Im Falle des Eintrags freier Luft in Öl bei den Hydraulikvibrationsdaten konnte mit den erlangten Merkmalen ein Klassifikationsfehler von 0% bei der Kreuzvalidierung (cv prediction) erreicht werden (vgl. Abb. 12). Zusätzlich werden sämtliche Prozessdaten zur Gruppvalidierung mit einer „Leave-One-Group-Out“ (LoGo) Kreuzvalidierung [8] herangezogen. Es wird also die Robustheit dieser Vorhersage gegenüber der Pumpenleckage, der Speicherleckage und dem Fehlverhalten des Ventils geprüft. All diese Validierungen erzielten einen Klassifizierungsfehler kleiner als 1% (vgl. Abb. 12).

Die Ergebnisse sind laut der Validierungen sowohl statistisch robust als auch robust gegenüber der genannten Parameter. Aufgrund des Verlaufs des besten Features (Abb. 6) bleibt die Robustheit gegenüber der Öltemperatur offen bzw. es bleibt offen, ob die Öltemperatur vorhergesagt wird statt des Lufteintrags.

## Diskussion und Ausblick

Trotz gründlicher Validierung ließ sich nur durch das direkte Betrachten der Merkmale (Abb. 6) eine grundlegende Problematik feststellen. Es sollten also Anpassungen im DoE vorgenommen werden, um Effekte wie Temperaturänderungen zu berücksichtigen oder umgehen zu können.

Der größte Nachteil liegt bei dieser Methode in der explosiv wachsenden Anzahl an Merkmalen bei steigender Anzahl an Segmenten. Das führt u.a. zu hoher Redundanz, die später per Selektion wieder ausgeglichen werden muss (MRMR).

Der Vorteil der vorgestellten Methode liegt in der flexiblen und nachvollziehbaren Extraktion von Merkmalen.

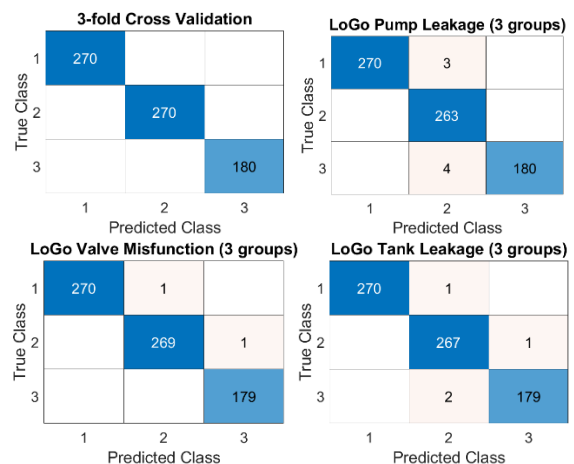


Abb. 12: Vibrationsdaten Hydraulik, Lufteintrag in Öl, Vorhersage der Klassifikation per LDAMahal mit vier Kreuzvalidierungsarten.

Außerdem bietet die Struktur auch die Möglichkeit mit logarithmischen Frequenzbändern, Ordnungsanalysen, Hüllkurven sowie beliebigen Zeit- und Frequenzbereichen zu arbeiten. All diese Variationen wurden am Lehrstuhl bereits verwendet. Diese Varianten sind als alternative Modi über die Definition von Name-Value-Pairs integrierbar und nutzbar.

In Kombination mit geschickter und bewusster Vorverarbeitung, leistet diese Methode gute Vorarbeit für Klassifikations- und Regressionsmethoden. Dabei kann man auch auf neuronale Netze abzielen, die dann mit den erzielten Merkmalen trainiert werden.

Die Nachvollziehbarkeit von Ergebnissen anhand der plausiblen Merkmale und die Problemidentifikation anhand der unplausiblen Merkmale stehen hier stets im Vordergrund.

### Literaturnachweis

- [1] A. Adadi, M. Berrada, "Peeking Inside the Black Box: A Survey on Explainable Artificial Intelligence (XAI)," *IEEE Access* Volume 6, 2018.
- [2] D. Rudresh, D. Devam, N. Het, S. Smiti, O. Rana, P. Pankesh, Q. Bin, W. Zhenyu, S. Tejal, M. Graham, R. Rajiv, "Explainable AI (XAI): Core Ideas, Techniques, and Solutions," *ACM Comput. Surv.* 55, 9, Article 194, 2023, <https://doi.org/10.1145/3561048>.
- [3] Technology Programme AI Innovation Competition of the Federal, "Explainable AI: Requirements, Use Cases and Solutions," Ministry for Economic Affairs and Climate Action, Germany (2022), online verfügbar: [https://www.digitale-technologien.de/DT/Redaktion/EN/Downloads/Publikation/KI\\_Inno\\_Xai\\_Studie.html](https://www.digitale-technologien.de/DT/Redaktion/EN/Downloads/Publikation/KI_Inno_Xai_Studie.html), letzter Aufruf: 16.05.2024.
- [4] T. Dorst, Y. Robin, T. Schneider, A. Schütze, "Automated ML Toolbox for Cyclic Sensor Data," *Joint Virtual Workshop of ENBIS and MATHMET Mathematical and Statistical Methods for Metrology MSMM*, 2021.
- [5] S. Lomba, J., F. Alves, M.I., "Moments," In: Daya Sagar, B., Cheng, Q., McKinley, J., Agterberg, F. (eds) "Encyclopedia of Mathematical Geosciences," "Encyclopedia of Earth Sciences Series," Springer, 2021, Cham. [https://doi.org/10.1007/978-3-030-26050-7\\_454-1](https://doi.org/10.1007/978-3-030-26050-7_454-1).
- [6] A. Maćkiewicz, W. Ratajczak, "Principal components analysis (PCA)," *Computers & Geosciences*, Volume 19, Issue 3, 1993, Pages 303-342, ISSN 0098-3004, [https://doi.org/10.1016/0098-3004\(93\)90090-R](https://doi.org/10.1016/0098-3004(93)90090-R).
- [7] P. Goodarzi, S. Klein, A. Schütze, T. Schneider; "Comparing Different Feature Extraction Methods in Condition Monitoring Applications," *IEEE I2MTC*, 2023.
- [8] P. Goodarzi, A. Schütze, T. Schneider, "Comparing AutoML and Deep Learning Methods for Condition Monitoring using Realistic Validation Scenarios," *arXiv preprint arXiv:2308.14632*, 2023.
- [9] T. Schneider, N. Helwig, A. Schütze, "Industrial condition monitoring with smart sensors using automated feature extraction and selection," *IOP Meas. Sci. Technol.*, 2018.
- [10] R. Wirth, "Maschinendiagnose an Industriegetrieben - praktische Signalidentifikation," *Antriebstechnik* 37, Nr. 11, S. 77-81, 1998.
- [11] S. Mecking, A. Mayr, U. Schanda, "Messung von Körperschall-Nachhallzeiten inhomogener Strukturen am Beispiel einer Holzbalkendecke," *DAGA*, Darmstadt, 2012.
- [12] L. Graham, F. Oppacher, "Hill-Valley," *UCI Machine Learning Repository*, 2008, <https://doi.org/10.24432/C5JC8P>.
- [13] A. Sturm, "Maschinen- und Anlagendiagnostik: Für die zustandsbezogene Instandhaltung," Stuttgart: Teubner, 1990, ISBN 3519063336.
- [14] A. Handl, "Multivariate Analysemethoden," Berlin: Springer, 2010, ISBN 3540433864.
- [15] N. Helwig, E. Pignanelli, A. Schütze, "Condition Monitoring of a Complex Hydraulic System using Multivariate Statistics," *IEEE International Instrumentation and Measurement Technology Conference*, Pisa, Italy, 2015.
- [16] N. Helwig, E. Pignanelli, A. Schütze, "Detecting and Compensating Sensor Faults in a Hydraulic Condition Monitoring System," *SENSOR 2015 - 17th International Conference on Sensors and Measurement Technology*, 2015, Nuremberg, Germany.
- [17] S. Klein, "Multivariate Auswertung spektraler Beschleunigungsdaten für das Condition Monitoring," *Bachelor-Thesis*, 2015, Saarland University, page 46, table 5, Saarbrücken.
- [18] Z. Zhenyu, R. Anand, M. Wang, "Maximum Relevance and Minimum Redundancy Feature Selection Methods for a Marketing Machine Learning Platform," *IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, 2019, 442-452., <https://doi.org/10.1109/DSAA.2019.00059>.
- [19] A. Tharwat, T. Gaber, A. Ibrahim, A. E. Hassani, "Linear discriminant analysis: A detailed tutorial," *Ai Communications*. 30. 169-190, 2017, <https://doi.org/10.3233/AIC-170729>.
- [20] G. Mclachlan, "Mahalanobis Distance," 1999, *Resonance*. 4. 20-26., <https://doi.org/10.1007/BF02834632>.