

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/333677019>

Intelligente Zustandsüberwachung durch akustische Analyse und Machine Learning

Preprint · June 2019

DOI: 10.13140/RG.2.2.25661.31200

CITATIONS

0

READS

530

6 authors, including:



Peter Burggräf

Universität Siegen

144 PUBLICATIONS 264 CITATIONS

SEE PROFILE



Ulf Lorenz

Universität Siegen

66 PUBLICATIONS 269 CITATIONS

SEE PROFILE



Ulrich Stache

Universität Siegen

14 PUBLICATIONS 6 CITATIONS

SEE PROFILE



Johannes Wagner

Universität Siegen

48 PUBLICATIONS 70 CITATIONS

SEE PROFILE

Some of the authors of this publication are also working on these related projects:



Remanufacturing [View project](#)



Engine of structural change? The impact of educational institutions in Liverpool and Aachen [View project](#)

Intelligente Zustandsüberwachung durch akustische Analyse und Machine Learning

Prof. Dr.-Ing. Peter Burggräf, Prof. Dr. Ulf Lorenz, Prof. Dr.-Ing. Ulrich Stache,
Dr.-Ing. Johannes Wagner, Till Saßmannshausen, Dennis Ohrndorf

Abstract: In the field of acoustic condition monitoring, well-trained specialists are frequently employed who are able to intuitively make a statement about the system condition on the basis of the acoustic signals of a machine. This paper presents an approach to intelligent condition monitoring that is able to predict the system condition of a coffee grinder similarly intuitively on the basis of its acoustic signals during the grinding process. The relevant information is extracted by means of a chromagram, which converts the recorded acoustic signal into a graphic representation and thus reduces its complexity at the same time. This allows the use of pattern recognition through supervised machine learning. The trained machine learning (ML) models are able to perform a binary classification with regard to the system state and thus to distinguish the grinding process at full from that at empty mill with high accuracy.

Keywords: condition monitoring, pattern recognition, supervised machine learning, acoustic signal, chromagram

Zusammenfassung: Im Bereich der akustischen Zustandsüberwachung werden häufig gut ausgebildete Fachkräfte eingesetzt, die in der Lage sind intuitiv eine Aussage über den Systemzustand anhand des akustischen Signals einer Maschine zu treffen. In diesem Aufsatz wird ein Ansatz der intelligenten Zustandsüberwachung vorgestellt, der in der Lage ist, den Systemzustand eines Kaffeemahlwerks anhand seiner Akustik beim Mahlvorgang ähnlich intuitiv vorherzusagen. Die relevanten Informationen werden über ein Chromagramm extrahiert, wodurch das aufgenommene akustische Signal in eine grafische Darstellung überführt und somit gleichzeitig dessen Komplexität reduziert wird. Dies ermöglicht die Verwendung einer Mustererkennung durch Supervised Machine Learning. Die trainierten Machine Learning (ML) Modelle sind in der Lage eine binäre Klassifizierung hinsichtlich des Systemzustands durchzuführen und so den Mahlvorgang bei vollem von dem bei leerem Mahlwerk mit hoher Genauigkeit zu unterscheiden.

Keywords: Zustandsüberwachung, Mustererkennung, Supervised Machine Learning, akustisches Signal, Chromagramm

1 Einleitung

Predictive Maintenance als vorausschauende Instandhaltungsstrategie löst immer mehr die *präventive Instandhaltung* ab und soll die Verfügbarkeit von Maschinen und Anlagen sicherstellen sowie den Instandhaltungsaufwand reduzieren [1]. Das Potenzial von *Predictive Maintenance* spiegelt sich in den Ergebnissen einer Untersuchung des Bundesministeriums für Bildung und Forschung wieder. Dieser zufolge beliefen sich die direkten Instandhaltungskosten im Jahr 2005 für Deutschland auf 175 Mrd. Euro und die indirekten Instandhaltungskosten (z. B. Maschinenausfallzeit) auf bis zu 875 Mrd. Euro [2]. Essentiell für *Predictive Maintenance* ist die durchgängige Überwachung der Maschine oder Anlage, das *Condition Monitoring* [3]. Hierfür haben sich digitale Technologien wie bspw. echtzeitfähige Systeme und Sensoren etabliert [4]. Die Herausforderung ist das richtige Maß zwischen Aufwand und Nutzen zu finden, da mit steigendem Überwachungsgrad auch die damit verbundenen Kosten steigen [5].

2 Forschungsvorhaben

Der vorliegende Aufsatz stellt einen neuen Ansatz vor, der mit wenig Aufwand ein robustes System schafft, das in der Lage ist zwei Systemzustände über deren akustische Signale nicht invasiv zu unterscheiden. Testsubjekt ist das Mahlwerk eines Kaffeevollautomaten, welches eine hörbar andere Akustik ausstrahlt, wenn es mit Kaffeebohnen gefüllt ist (Klasse 1), als wenn es sich im Leerlauf befindet (Klasse 0).

Aufgrund der guten akustischen Unterscheidbarkeit der beiden Zustände soll ein Ansatz gewählt werden, der das akustische Empfinden des Menschen möglichst korrekt, aber in vereinfachter Form widerspiegelt. Um eine Veränderung im Frequenzspektrum feststellen zu können sind standardmäßige Wellendarstellungen des Audiosignals ungeeignet. Hier kann das Frequenzspektrum nicht direkt abgelesen werden, da sich ein reales Signal üblicherweise aus mehreren unterschiedlichen Sinusschwingungen zusammensetzt und somit zunächst in seine Bestandteile zerlegt werden muss. Daher wird das Signal in dem hier betrachteten Fall in eine *Chroma*-Darstellung transformiert. Diese Darstellung hat sich in der Musiktheorie bewährt, da hier für den Menschen ähnlich empfundene Töne zusammengefasst werden [6]. Dadurch wird eine akustische Signalverarbeitung ermöglicht, die der des menschlichen Gehörs sehr ähnlich ist. Das Chromagramm schafft damit einen Kompromiss zwischen Informationsgehalt und Komplexität.

Die *Chroma-Features* werden mithilfe der Python-Bibliothek `librosa` extrahiert, welche zur Berechnung eine *Fixed Window Short Time Fourier Transformation* verwendet [7]. Dadurch kann der gesamte Frequenzbereich des aufgenommenen Signals in einer stark vereinfachten Darstellungsform durch 12 diskrete Tonhöhenklassen (Pitch Classes) visualisiert werden. Wie in Abbildung 1 zu sehen, ist der Unterschied des akustischen Signals in dieser Darstellungsform deutlich zu erkennen. Hier wird die Intensität der Tonhöhenklasse relativ zueinander in einem Intervall von 0 bis 1 dargestellt. Je heller das Feld, desto höher die Intensität.

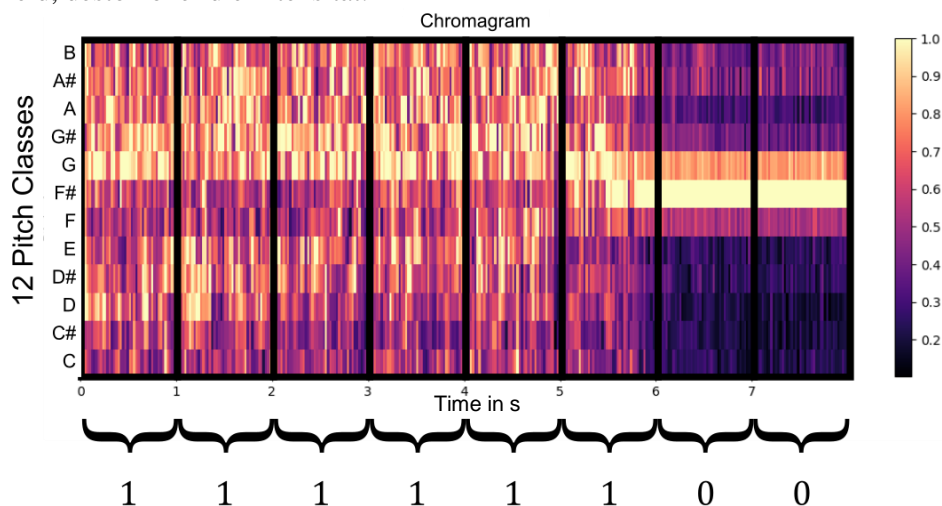


Abbildung 1. Akustisches Signal unter Last [0s; 6s] und im Leerlauf [6s; 8s]

Um die intuitive Mustererkennung des Menschen zu reproduzieren haben sich in der Vergangenheit unter anderem Ansätze des *Supervised Machine Learning* durchgesetzt. Bei dieser Art des ML erlernt das Modell, auf Basis von bereits klassifizierten Trainingsdaten eine Merkmalsverteilung, die anschließend die Klassifizierung von unbekanntem Daten ermöglicht [8-9]. Die betrachteten Modelle sind *Support Vector Machine* (SVM) [10] und *Künstliche Neuronale Netze* (KNN) [11-12]. Die Trainingsdaten sind in diesem Fall für beide Modelle die entsprechenden Chroma-Features. Die unbekanntem Daten (Testdaten) sind hier neue Audiodateien desselben Kaffeemahlwerks.

3 Stand des Forschungsvorhabens

Der verwendete Workflow zum Trainieren der beiden ML-Modelle ist in Abbildung 2 dargestellt. Zunächst wird das akustische Signal des Mahlwerks mehrmals im Lastbetrieb sowie im Leerlauf mit einem Mikrophon aufgenommen und die daraus entstehende .wav-Datei gespeichert. Jede dieser Dateien wird aufgeteilt, sodass mehrere Zeitfenster der Länge 1s aus dem gesamten Mahlvorgang entstehen. Diese werden anschließend manuell gelabelt.

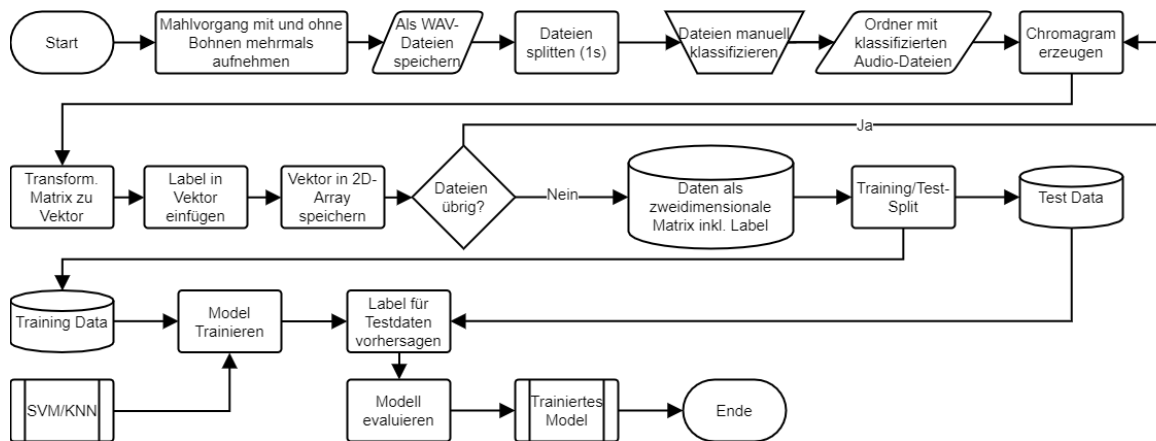


Abbildung 2. Workflow: Datenaufbereitung und Training der ML-Modelle

Jede Datei wird in ein Chromagramm umgewandelt und die Chroma-Features sowie die tatsächliche Klasse (das Label) in einer Zeile eines zweidimensionalen Arrays gespeichert. Dieses Array stellt die Rohdatenbasis dar. Die Datenbasis (136 Datensätze à eine Sekunde) wird anschließend zeilenweise randomisiert und mit dem Verhältnis 80/20 in Test- und Trainingsdaten aufgeteilt [13]. SVM und KNN werden anschließend mit denselben Trainingsdaten trainiert.

Tabelle 1. Konfusionsmatrizen und Genauigkeit der beiden trainierten Modelle

	SVM		KNN	
	Vorhersage 0	Vorhersage 1	Vorhersage 0	Vorhersage 1
Tatsächlich 0	10	2	11	1
Tatsächlich 1	0	14	0	14
Genauigkeit	92,31%		96,15%	

Tabelle 1 zeigt die Ergebnisse der Tests: Beide Algorithmen sind in der Lage einen Großteil der unbekanntem Testdaten (26 Datensätze) korrekt zu klassifizieren. Somit ergibt sich für die SVM die Genauigkeit 92,31% für das KNN 96,15%. Die Konfusionsmatrizen zeigen außerdem, dass bei den hier betrachteten Testdaten die Schwierigkeit hauptsächlich in der korrekten Klassifizierung von negativen Exemplaren (Klasse 0) liegt. Zu erkennen ist dies daran, dass SVM zweimal eine positive Vorhersage trifft (Vorhersage 1), wenn es sich eigentlich um ein negatives Exemplar handelt (Tatsächlich 0). Beim KNN tritt der gleiche Fehler nur einmal auf.

4 Fazit

Die Vorhersagegenauigkeit (Tabelle 1) zeigt, dass sich die beiden ML-Modelle zur binären Klassifizierung des Systemzustandes des Kaffeemahlwerks eignen. Damit lässt sich der erste Schritt des Forschungsvorhabens als erfolgreich beendet bezeichnen. Weitere Schritte sind erforderlich, um eine industrielle Verwendung nachzuweisen. Dazu zählt der Echtzeiteinsatz der trainierten Modelle (Data Stream), der sekundlich den Maschinenzustand der Kaffeemaschine bewertet und eine Meldung abgibt, sobald der Normalzustand verlassen wird. Hier wird die größte Herausforderung darin gesehen, den Zeitverzug zwischen Datenaufnahme und Bewertung minimal zu halten.

Des Weiteren wird aufgrund der methodischen Verwendung des Chromagramms eine Robustheit hinsichtlich des Mikrofons erwartet. Die zu beantwortende Frage ist, welchen Minimalanforderungen das Mikrofon genügen muss, um die gewünschten Ergebnisse zu generieren. Durch günstigere Mikrofone kann das Aufwand-Nutzen-Verhältnis für das Nachrüsten einer Maschine oder Anlage weiter verbessert werden.

Nach diesen Schritten ist eine Transformation in die Industrie erforderlich. Im Feld gilt es zu untersuchen, für welche Maschinen und Anlagen oder auch Anwendungsfälle die entwickelte Methode einsetzbar ist und wo sie durch ihre starke Komplexitätsreduktion des Chromagramms an ihre Grenzen stößt. In diesen Fällen eignen sich möglicherweise andere Darstellungsformen, wie das Spektrogramm.

5 Literaturverzeichnis

1. Strunz, M.: Instandhaltung - Grundlagen, Strategien, Werkstätten. Springer, Berlin, Heidelberg (2012)
2. Kuhn, A., Schuh, G., Stahl, B.: Nachhaltige Instandhaltung. VDMA Verlag, Frankfurt a. M. (2006)
3. Voigt, K., Steinmann, F., Bauer, J. et al.: Condition Monitoring als Schlüssel-technologie. Eine Analyse der Anforderungen an neue Geschäftsmodelle für den Remote Service. Symposium für Vorausschau und Technologieplanung. Berlin (2013)
4. Lange, E.: Condition Monitoring: Überwachung für Anlagen geht online, <https://www.ingenieur.de/technik/fachbereiche/condition-monitoring-ueberwachung-fuer-anlagen-geht-online/> (Zugriff: 13.09.2018)
5. Hölbfer, S.: Modell zur Auswahl von Instandhaltungsstrategien in anlagenintensiven Industriebetrieben. Dissertation. Loeben (2014)
6. Deutsch, D., Boulanger, R. C.: Octave equivalence and the immediate recall of pitch sequences. *Music Perception: An Interdisciplinary Journal* 2(1), 40-51 (1984)
7. McFee, B., Raffel, C., Liang, D., Ellis, D. P., McVicar, M., Battenberg, E., Nieto, O.: Librosa: Audio and music signal analysis in python. In: Proceedings of the 14th python in science conference, Austin, 18-25 (2015)
8. Kotsiantis, S.B., Zaharakis, I., Pintelas, P.: Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering* 160, 3-24 (2007)
9. Burggräf, P., Wagner, J., Koke, B.: Artificial Intelligence in Production Management, A review of the current state of affairs and research trends in academia. *International Conference on Information Management and Processing (ICIMP)*, IEEE, London, 2-88 (2018)
10. Vapnik, V.N., Chervonenkis, A.J.: *Theory of pattern recognition*, Nauka, Moskau (1974)
11. McCulloch, W.S., Pitts, W.: A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics* 5(4), 115-133 (1943)
12. Rosenblatt, F.: The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review* 65(6), 386 (1958)
13. Géron, A.: *Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems*. O'Reilly Media Inc., 49 (2017)