

## Entwicklung und Beurteilung von Machine Learning Klassifikationen

# Maschinenübertragbare Online-Rattererkennung

C. Brecher, R. Klmaschka, S. May, S. Neus

**ZUSAMMENFASSUNG** Diese Arbeit untersucht die Umsetzbarkeit verschiedener Klassifikationsalgorithmen zur echtzeitfähigen, maschinenunabhängigen Rattererkennung. Basierend auf 136 Messungen werden zwei neue Klassifikationsmethoden entwickelt, die eine Genauigkeit von durchschnittlich 92 % erreichen. Sie basieren auf einer einfachen Messkette, die Stabilitätsrelevante Informationen aus einem Beschleunigungssensor und einem Spindeldrehgeber bezieht und somit für die industrielle Praxis geeignet sind.

### STICHWÖRTER

Fräsen, Sensoren, Künstliche Intelligenz (KI)

## Machine-Transferable Online Chatter Detection: Development and Evaluation of ML Classifications

**ABSTRACT** This study investigates the feasibility of various classification algorithms for real-time, machine-independent instability detection in milling processes. Based on 136 measurements with 5.6 million data points, two new classification methods are developed, which achieve an average accuracy of 92 %. They are based on a simple sensor setup that obtains stability-relevant information from an acceleration sensor and a spindle encoder, making them suitable for industrial applications.

## 1 Einleitung

Die steigende Nachfrage nach Bauteilen für die E-Mobilität stellt hohe Anforderungen an die Effizienz und Qualität zerspannder Fertigungsverfahren. Insbesondere bei der Bearbeitung filigraner und funktionskritischer Komponenten, wie beispielsweise in Elektromotoren oder Batteriegehäusen, gewinnt die Prozesssicherheit zunehmend an Bedeutung. In diesem Kontext rückt die Fräsbearbeitung als flexibles Fertigungsverfahren in den Fokus. Hohe Zeitspanvolumina, anspruchsvolle Oberflächenqualitäten sowie die Reduktion von Maschinen- und Werkzeugschäden sind entscheidend, um die Anforderungen moderner Produktionslinien in der E-Mobilität zuverlässig und skalierbar zu erfüllen.

Dabei stellen neben der Spindelleistung vor allem dynamische Phänomene wie das regenerative Rattern wesentliche Einschränkungen für die Produktivität in der Fräsbearbeitung dar. Neben Produktivitätseinbußen [1] kann es durch Rattern außerdem zu Qualitätsmängeln am Werkstück oder Maschinen- und Werkzeugschäden [2] kommen. Durch eine geeignete Wahl der Prozessparameter ist es jedoch möglich, eine stabile, aber dennoch produktive Bearbeitung zu gewährleisten. Zur effizienten Ermittlung dynamischer Stabilitätsgrenzen kommen sensorbasierte Rattererkennungsalgorithmen zum Einsatz. Bisherige Rattererkennungsmethoden sind jedoch häufig abhängig von festgelegten Grenzwerten, wobei Machine Learning (ML) Algorithmen Abhilfe schaffen können.

Trotz zahlreicher Forschungsarbeiten zur Online-Rattererkennung, die verschiedene Ansätze verfolgen, bleibt ihre Validierung meist auf einen spezifischen Prozess beschränkt. Auch in [3] wird

betont, dass die Auswahl von Merkmalen und Grenzwerten stark von den verwendeten experimentellen Randbedingungen abhängt. Hier werden über 100 Veröffentlichungen zur Rattererkennung miteinander verglichen.

**Bild 1** fasst 16 exemplarische Publikationen zusammen, die diese These stützen. Diese Arbeit (letzte Spalte in Bild 1) unterscheidet sich vor allem durch die Nutzung mehrerer Maschinen und Werkzeuge, um die Übertragbarkeit der hier entwickelten Rattererkennung zu validieren.

## 2 Versuchsaufbau

Die im Rahmen dieser Arbeit gewonnenen Ergebnisse stützen sich auf Messungen, die an vier verschiedenen Werkzeugmaschinen durchgeführt wurden: einer horizontalen 4-Achs-Maschine mit erreichbaren Spindeldrehzahlen von bis zu 12 000 1/min und einer B-Achse als Schenkrundtisch (A), einer High-Speed-Cutting Maschine mit bis zu 30 000 1/min und einer B-Achse als Teil eines parallelkinematischen Vorsatzfräskopfes (B), einer vertikalen Doppelspindel-Maschine mit bis zu 15 000 1/min (C) sowie einem vertikalen Bearbeitungszentrum mit bis zu 15 000 1/min (D). Die Datenerhebung erfolgt nach dem gleichen Verfahren mittels eines Beschleunigungssensors, der werkzeugnah am Spindelgehäuse montiert ist. Dieser erfassst die Beschleunigung in allen drei Raumrichtungen. Eine Übersicht der Versuchsausprägungen ist in der **Tabelle** dargestellt.

Insgesamt basieren die Ergebnisse dieses Beitrags auf 136 Versuchen, aus denen 5,6 Millionen verwertbare Datenpunkte gewonnen wurden. Jeder Datenpunkt repräsentiert eine abgetastete Beschleunigungsamplitude in drei Raumrichtungen.

		ja	nein	BREC17	JI18	CHE19	TRAN19	SCHM19	LU21	TRAN21	ZHAO21	CHE22	HAUP22	PERR22	WANG22	XU22	ZHEN22	UNVE23	ZHAN23	BREC25
Datenaufnahme	Beschleunigung	●	○	●	●	●	○	●	●	○	●	○	●	●	●	●	●	●	●	
	Kraft	○	○	○	○	○	●	○	○	○	○	○	●	●	●	○	●	●	●	
	Akustik	○	○	○	○	○	●	●	○	○	○	○	○	○	○	○	○	○	○	
	Oberflächenaufnahme	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	
	Simulation	○	○	○	●	○	●	●	●	●	●	●	●	●	●	●	●	●	●	
Prozessvariation	Prozessparametervariation	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
	Mehrere Maschinen	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	○	
Auswertungsart	Zeitauswertung	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
	Frequenzauswertung	○	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
	Beschleunigungsauswertung	○	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
	Verlagerungsauswertung	●	○	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
Klassifizierungsinput	Bild	○	○	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
	Extrahierte Merkmale	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
Klassifizierungsaart	Hyperebenenklassifikation	○	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
	Neuronales Netz	○	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
Abhängigkeiten	Grenzwertabhängig	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	
	Eigenfrequenzabhängig	○	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	●	

**Bild 1.** Vergleichsmatrix  
Grafik: WZL

**Tabelle.** Versuchsausprägung

Maschine	A	B	C	D
Werkzeuganzahl	2	1	2	1
Werkzeugtyp	Schaftfräser und Messerkopf	Schaftfräser	Schaftfräser und Messerkopf	Schaftfräser
Werkstückmaterial	Stahl	Aluminium	Aluminium, Stahl	Stahl
Schnitttiefe	3 - 9,02 mm	2 - 9 mm	1,5 - 2,4 mm	1,2 - 2,6 mm
Schnittart	Vollnut	Voll-, Teilnut in Gleich-, Gegenlauffräsen	Voll-, Teilnut in Gleich-, Gegenlauffräsen	Vollnut
Drehzahl	1.200 – 1.500 U/min	25.000 – 29.000 U/min	2.800 – 3.325 U/min	3.700 – 5.300 U/min
Abtastrate	5.120 Hz	51.200 Hz	5.120 Hz	5.120 Hz
Anzahl Messungen	38	19	72	7

Daraus ergeben sich 9.387 relevante Batches. Ein Batch ist ein Datenpaket, für das eine binäre Stabilitätsbewertung vorgenommen wird, basierend auf den innerhalb von vier Spindelumdrehungen erfassten Datenpunkten. Insgesamt beträgt das Stabilitätsverhältnis 38,4 % instabile zu 61,6 % stabile Batches. Die Messungen umfassen sowohl hoch- als auch niederfrequente Ratterfrequenzen.

### 3 Labelmethode

Die Grundlage für die Entwicklung und Beurteilung mehrerer ML- und weiterer Klassifikationsmethoden ist das Labeln der Messdaten. Dabei werden die Labelergebnisse mehrerer Einzelmethoden gewichtet addiert.

Die erste der drei Einzelmethoden basiert auf der Fast Fourier Transformation (FFT) und vergleicht die maschinenbekannten Eigenfrequenzen mit der vorliegenden Messung. Dies erfolgt sowohl für die gemessene Beschleunigung als auch für die daraus resultierenden Geschwindigkeits- und Verlagerungsergebnisse in

der Hauptbearbeitungsebene (X- und Y-Richtung). Die zweite Einzelmethode beschreibt das manuelle Labeln, bei dem Beschleunigungsmessungen und Verlagerungsdarstellungen mithilfe von Expertenwissen ausgewertet werden. Die dritte Einzelmethode umfasst zwei Grenzwertverfahren, darunter ein Verfahren, das auf der Poincaré-Abbildung beruht [20].

### 4 Merkmalsextraktion

Die extrahierten Merkmale, die stabilitiesrelevante Informationen enthalten und als Input für zwei von insgesamt vier untersuchten Klassifikationsverfahren dienen, beruhen auf der in dieser Arbeit vorgestellten Umdrehungsdurchschnittsdifferenz (UDD).

Nach der Messung eines Batchs, das in **Bild 2** (oben links) durch die beiden roten vertikalen Linien im zeitlichen Verlauf der Beschleunigung dargestellt wird, kann durch doppeltes Integrieren und periodische Regression eine dreidimensionale Verlagerungsdarstellung, der nahe am Tool Center Point (TCP) befindli-

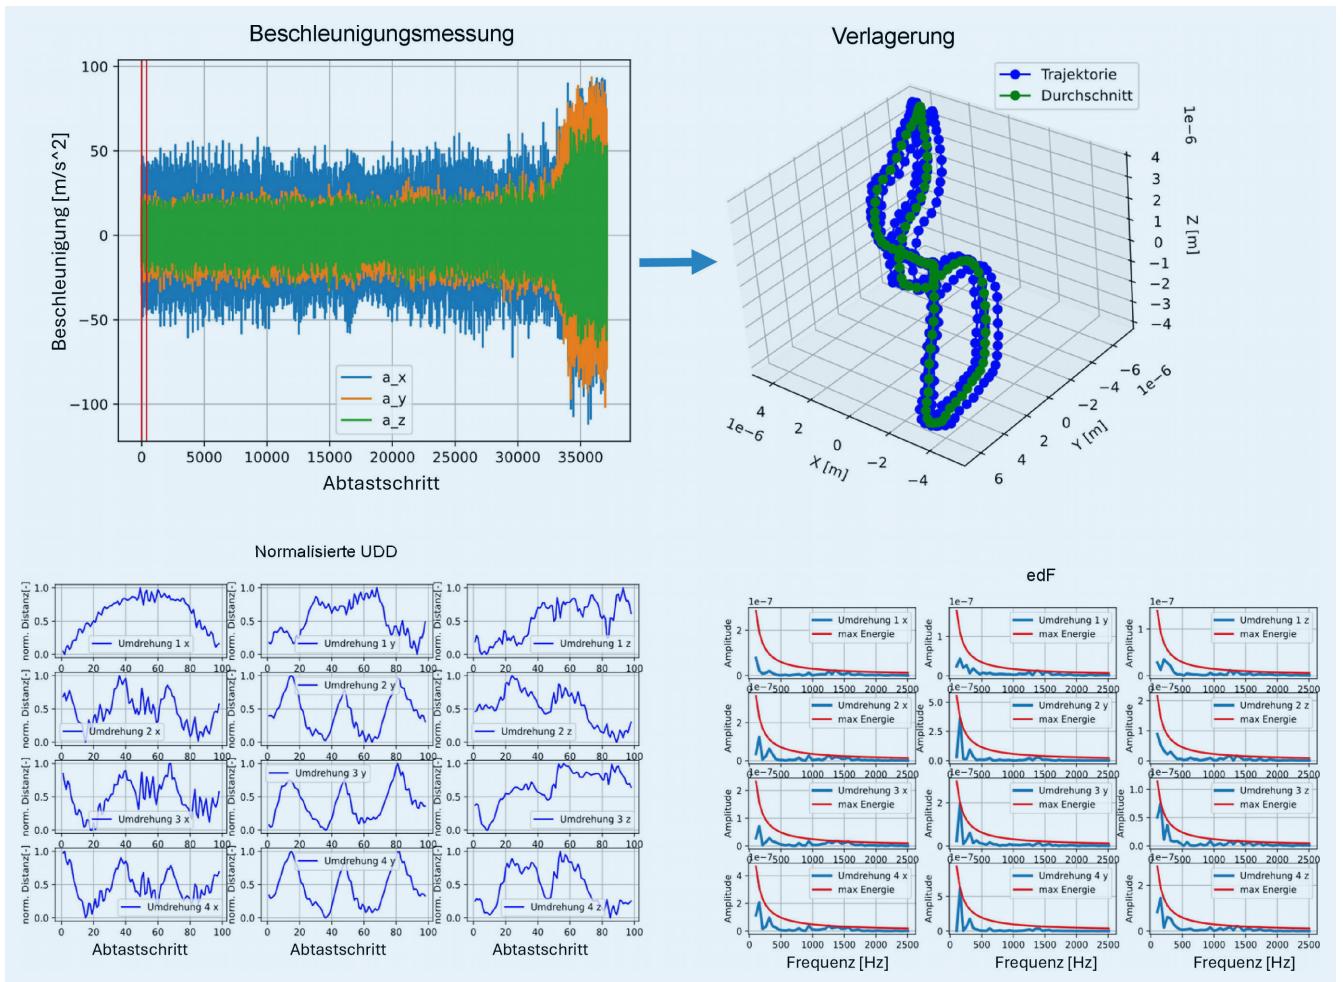


Bild 2. Signalverarbeitung von Beschleunigungsmessung zur Verlagerung. Grafik: WZL

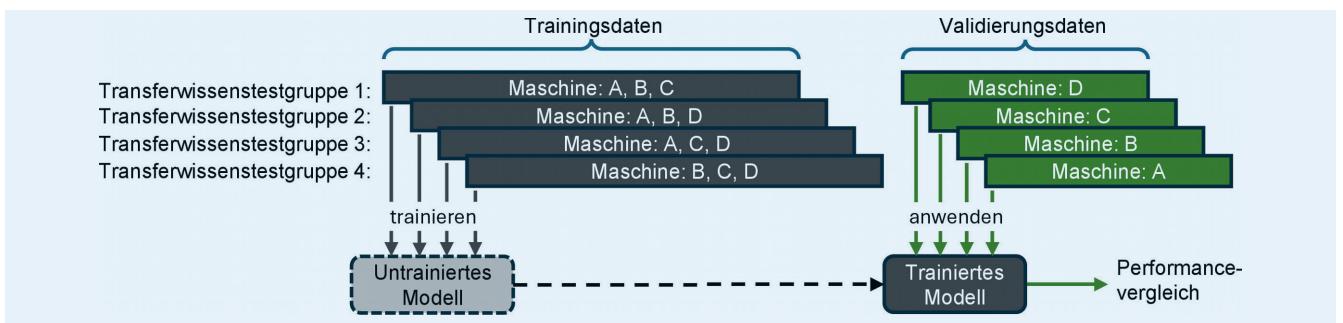


Bild 3. Aus der Verlagerung abgeleitete UDD für vier Umdrehungen und jeweils drei Raumdimensionen. Grafik: WZL

chen Messposition, berechnet werden. Dies wird anhand eines stabilen Batchs in Bild 2 visualisiert.

Durch die Hinzunahme der Durchschnittsverlagerung, also der durchschnittlichen Verlagerung eines Stützpunkts über vier Spindelumdrehungen, ist es möglich, jede der vier Umdrehungstrajektorien davon zu subtrahieren. Dies geschieht für alle drei Raumdimensionen, wodurch zwölf UDD-Verläufe pro Batch entstehen (**Bild 3**). So kann für jeden zeitlich bestimmten Abtastschritt eine Differenz zwischen der tatsächlichen und der durchschnittlichen Umdrehung gebildet werden, die in der UDD-Darstellung in Bild 2 zu sehen ist. Auf diese Weise werden Frequenzen, die peri-

odisch zur Spindeldrehzahl stehen, wie beispielsweise die Messereigniffsfrequenz, effektiv herausgefiltert.

Im letzten Schritt wird jede UDD mithilfe einer FFT-Analyse in ihre Frequenzkomponenten zerlegt (blauer Verlauf **Bild 4**). Anschließend wird die energetisch dominierende Frequenz (edF) ermittelt. Diese ist in Bild 4 durch den roten Verlauf dargestellt und zeigt das maximale Energieniveau der jeweiligen UDD und dessen FFT-Auswertung. Nach [21] wird die Energie eines Einmassenschwingers durch folgende Gleichung beschrieben:

$$E_{ges} = 0,5 \cdot m \cdot \omega^2 \cdot A^2 \quad (1)$$

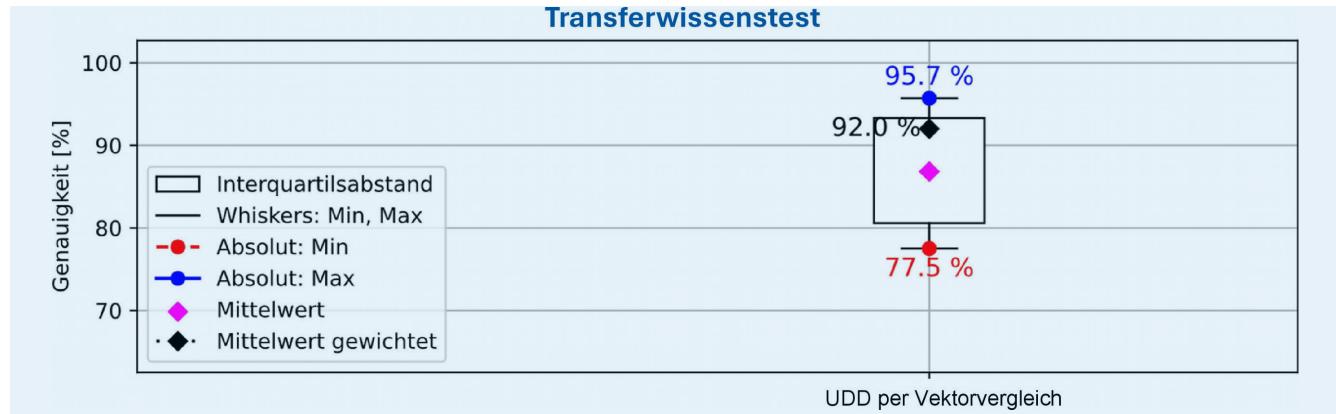


Bild 4. Aus der UDD abgeleitete edF für vier Umdrehungen und jeweils drei Raumdimensionen. Grafik: WZL

Diese gilt für den Fall der maximalen Auslenkung der Masse, also  $E_{ges} = E_{pot}$  und  $E_{kin} = 0$ . Die Masse ist dabei  $m$ , die Schwingfrequenz  $\omega$  und die dazugehörige Amplitude  $A$ . Daraus lässt sich das folgende Proportionalitätsverhältnis für die edF ableiten:

$$edF \propto \omega^2 \cdot A^2 \quad (2)$$

Da jeweils  $\omega$  und  $A$  durch die FFT-Analyse bekannt sind, lässt sich die edF jeder UDD auf diese Weise ermitteln.

Der Hintergrund für die UDD-Methode leitet sich aus dem (vermeintlich) chaotischen Verhalten instabiler Verlagerungstrajektorien [22] ab. Die Idee ist folgende: Ist ein Batch stabil, unterscheidet sich jede Umdrehungstrajektorie nur geringfügig von der Durchschnittstrajektorie. Ist ein Batch instabil, zeigen sich deutliche Unterschiede zur Durchschnittstrajektorie in der UDD. Bei instabilen Zerspanzuständen überlagern sich die Verlagerungstrajektorien mit der dominanten Ratterfrequenz. Dies geschieht sowohl im hoch- als auch im niederfrequenten Bereich. Durch die Subtraktion dieser Trajektorien von der Durchschnittstrajektorie lässt sich die angeregte dominante Schwingung in der Nähe einer Eigenfrequenz gezielt extrahieren.

Die Merkmale zur Stabilitätsbewertung entstehen durch den Vergleich der edF jeder UDD. Da weder Grenzwerte noch systemimmanente Eigenfrequenzen einbezogen werden und ausschließlich der edF-Vergleich ausschlaggebend ist, bleibt die UDD-Methode im Kern unabhängig von spezifischen Randbedingungen.

## 5 Klassifikationsmethoden

Es werden vier Klassifikationsansätze miteinander verglichen: die UDD-Klassifikation auf Basis des edF-Vektorvergleichs, mehrere ML-Modelle basierend auf UDD-extrahierten Merkmalen, zwei Bildklassifikationen mittels neuronaler Netzwerke (NN) anhand der zweidimensionalen Verlagerungsdarstellung [23] sowie eine Methode mit empirisch ermittelten Grenzwerten [20]. Diese werden im sogenannten Transferwissenstest gegenübergestellt (Bild 5). Dabei erfolgt das Training mit Messdaten von drei Maschinen, während das trainierte Modell auf die Messungen einer unbekannten, nicht für das Training genutzten Maschine angewendet wird. Der Transferwissenstest umfasst vier Gruppen und wird für alle Performanceanalysen der Klassifikationsmethoden siebenmal wiederholt, um die statistische Varianz nichtdeterministischer Klassifikationsmethoden zu berücksichtigen.

Zudem gibt ein weiterer Test, der Gesamttest, Aufschluss über die statistische Varianz nichtdeterministischer Klassifikationsmethoden. Hierbei werden die gelabelten Messungen aller vier Maschinen im Verhältnis 80/20 zufällig in Trainings- und Testdaten unterteilt. Für jede der KI-Klassifikationen wird eine Hyperparameteroptimierung im Rahmen einer Sensitivitätsanalyse durchgeführt. Die Ergebnisse der jeweils besten Hyperparameterkombinationen für die einzelnen Klassifikationsmethoden werden nachfolgend dargestellt.

### 5.1 UDD-Klassifikation per edF-Vektorvergleich

In der UDD-Klassifikation per edF-Vektorvergleich wird die edF pro Umdrehung und pro Bearbeitungssachse in der Hauptbearbeitungsebene (X-Y-Ebene) direkt miteinander verglichen:

$$[edF_{x1}, edF_{x2}, edF_{x3}, edF_{x4}] = [edF_{y1}, edF_{y2}, edF_{y3}, edF_{y4}] \quad (3)$$

Nur wenn beide Vektoren exakt gleich sind, handelt es sich um einen instabilen Batch.

Der Transferwissenstest der UDD-Klassifikation per edF-Vektorvergleich weist eine Varianz von 18,2 Prozentpunkten auf. Dies lässt sich auf die vier verschiedenen Transferwissenstestgruppen zurückführen (siehe Bild 6). Für den Validierungsdatensatz der Maschine A werden beispielsweise 77,5 % und für Maschine C 95,7 % Klassifikationsgenauigkeit erreicht. Der gewichtete Mittelwert liegt bei 92 % und hängt von der Anzahl der Datenpunkte pro Validierungsdatensatz ab. Je höher die Anzahl der Datenpunkte pro Validierungsdatensatz, desto mehr Gewicht hat die dazugehörige Klassifikationsgenauigkeit.

Alternativ kann der edF-Vektorvergleich über drei (X-Y-Z) statt zwei (X-Y) Achsen erfolgen, wodurch sich die Gesamtgenauigkeit von 92 % auf 91 % reduziert. Da die Steifigkeit in Z-Richtung in der Regel höher ist, treten in dieser Achse über mehrere Umdrehungen tendenziell geringere dominante Ratterschwingungen, welche der Z-Bewegung überlagert sind, auf.

Die UDD-Klassifikation per edF-Vektorvergleich erreicht aus mehreren Gründen keine perfekte Klassifikationsgenauigkeit. Durch die periodische Regression wird bei der TCP-Verlagerung mit überlagerter Ratterschwingungen nicht die tatsächliche, sondern eine approximierte Verlagerungstrajektorie berechnet. Verlagerungen mit überlagerten niederfrequenten Ratterschwingungen weisen häufig größere Verlagerungsamplituden auf als solche mit hochfrequenter Ratterschwingungen. Deswegen entsteht durch die

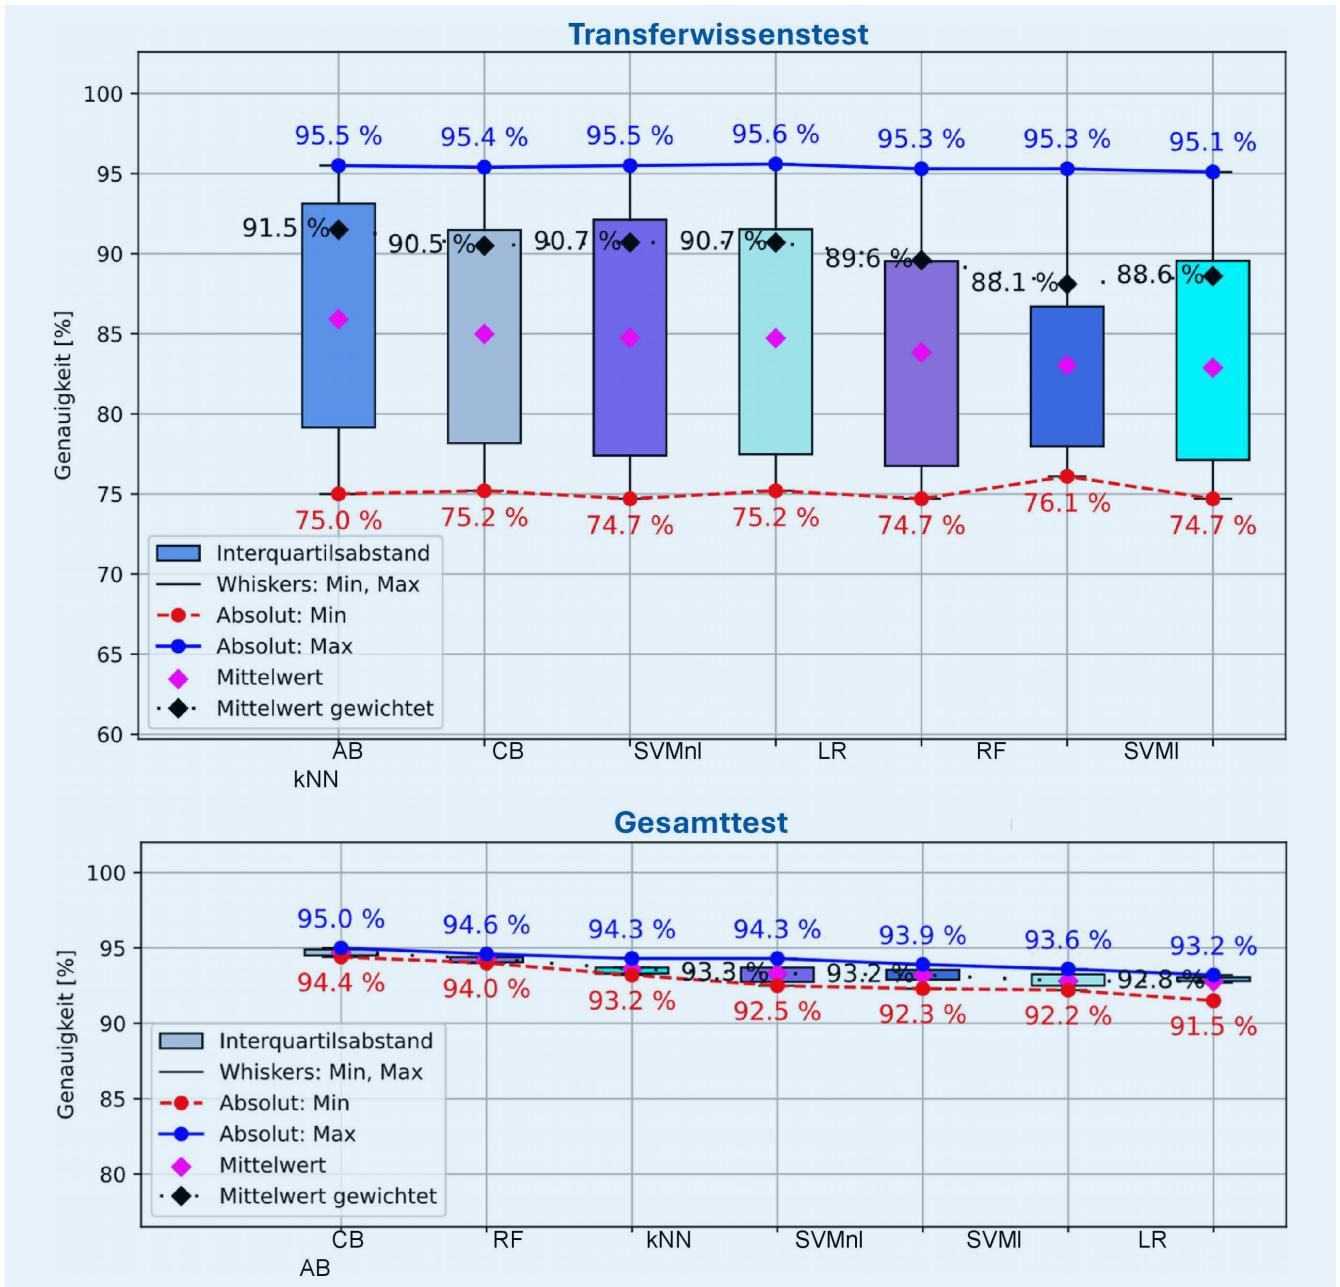


Bild 5. Transferwissenstest. Grafik: WZL

verwendete periodische Regression immer ein Fehler, abhängig von der Größe der Amplitude der überlagerten Ratterschwingung. Dies äußert sich darin, dass vor allem niederfrequente Ratterfrequenzen etwas schlechter mittels UDD-Methode klassifiziert werden als hochfrequente (siehe Maschine A mit 77,5 % Klassifikationsgenauigkeit und überwiegend niederfrequenten Ratterschwingungen). Ein weiterer Grund für die reduzierte Genauigkeit liegt in der begrenzten Präzision der Labeldaten. Fehlerhafte Label können sowohl False Positives als auch False Negatives verursachen, wenn Datenpunkte inkorrekt zugewiesen werden. Zudem wird in 1,9 % der Fälle die drehzahlbedingte Grenze der UDD erreicht (siehe 5.5 Grenzen UDD-basierter Klassifikationsmethoden). Darüber hinaus hat die Anzahl der Umdrehungen pro Batch eine Auswirkung auf die Genauigkeit. Mehr Umdrehungen verbessern die Durchschnittstrajektorie und

erhöhen die Genauigkeit der UDD. Allerdings führen mehr Umdrehungen pro Batch auch zu einer geringeren Klassifikationsfrequenz, weshalb hier eine anwendungsspezifische Abwägung erforderlich ist. Abschließend ist es denkbar, dass verschiedene Instabilitätsursachen Einfluss auf die Klassifikationsgenauigkeit haben können. Beispielsweise können Lagekopplungen, eine fallende Schnittkraft-Schnittdgeschwindigkeits-Charakteristik sowie die Bildung von Aufbauschneiden [24] einen zum regenerativen Rattern unterschiedlichen Einfluss auf die Klassifikationsgenauigkeit haben.

Wegen des deterministischen Verhaltens dieser Methode ist kein Training erforderlich. Außerdem wird eine echtzeitfähige Anwendung gewährleistet, da eine binäre Klassifikationsaussage durchschnittlich 22-mal schneller generiert werden kann als die Messdauer eines Batchs.

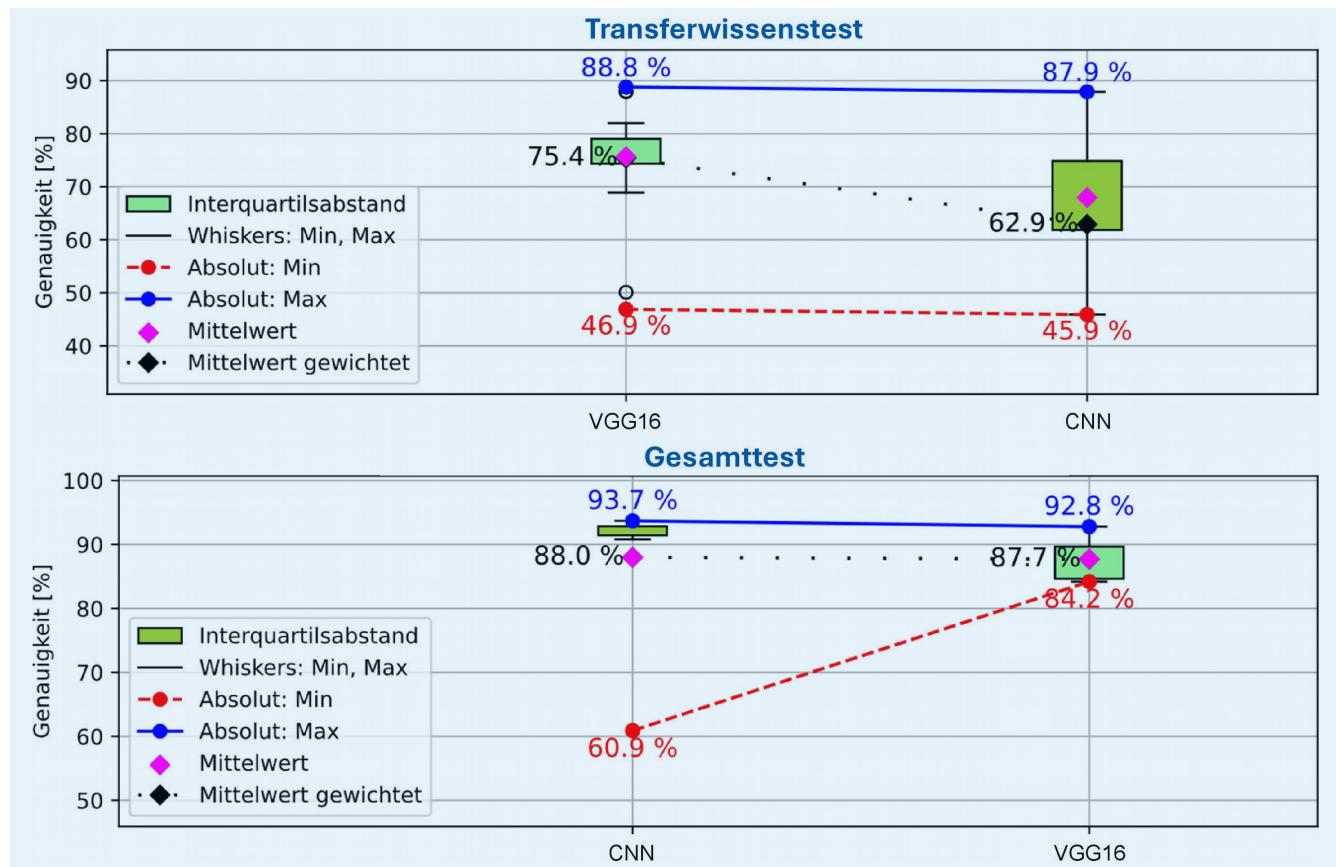


Bild 6. UDD-Klassifikation per edF-Vektorvergleich. Grafik: WZL

## 5.2 ML-Klassifikation mittels UDD-Merkmale

Die Merkmale, die als Input für die angewendeten ML-Klassifikationsmethoden dienen, basieren ebenfalls auf der UDD. Es wird die edF der jeweiligen UDD auf drei unterschiedliche Weisen in der Hauptbearbeitungsebene paarweise verglichen. Der erste Vergleich liefert eine Aussage bezüglich der edF-Gleichheit pro Paarvergleich. Im zweiten Vergleich wird überprüft, ob ein größter gemeinsamer Nenner vorliegt. Im dritten Vergleich wird das edF-Verhältnis paarweise bestimmt. Daraus ergeben sich insgesamt 21 Gleitkommazahlen zwischen 0 und 1, die als Input für die ML-Algorithmen dienen.

In Bild 7 werden sieben verschiedene ML-Klassifikationen miteinander verglichen: AdaBoost (AB), Support Vector Machine non-linear (SVMnl), CatBoost (CB), Logistic Regression (LR), Random Forest (RF), Support Vector Machine linear (SVMI) und k-Nearest Neighbor (kNN). Zur binären Klassifikation wurden bewusst verschiedene Modelle ausgewählt, um sowohl lineare als auch nicht-lineare Zusammenhänge abilden zu können. Die Auswahl umfasst etablierte Verfahren wie SVM (linear und nicht-linear), RF und AB, leistungsstarke Boosting-Modelle wie CB sowie einfachere Basismodelle wie kNN und LR zum Vergleich. Die Methode, die im Transferwissen am besten abschneidet, ist das AB-Verfahren, mit einer gewichteten Durchschnittsgenauigkeit von 91,5 % (siehe Bild 7 oben). Die Varianz ist auch hier auf die Transferwissenstestgruppen zurückzuführen (siehe Bild 5). Im Gegensatz zur UDD-Klassifikation per edF-Vektorvergleich gibt es jedoch eine Abhängigkeit von den Trainingsdaten, wodurch diese und jegliche andere Form von KI-Klassifikation unumgäng-

lich zu einer trainingsdatenabhängigen beziehungsweise grenzwertanhängigen Methode wird. Das liegt daran, dass ein ML-Algorithmus nur die Instabilitätszusammenhänge erlernen kann, die in den Trainingsdaten enthalten sind. Die Optimierung der Hyperebene hängt somit von den Merkmalen und den Trainingsdaten ab. Der wesentliche Vorteil gegenüber der UDD-Klassifikation per edF-Vektorvergleich ist somit die Möglichkeit, mehrere Instabilitätsursachen durch unterschiedliche Merkmale zu betrachten. Dies begründet die Existenzberechtigung trainingsdatenabhängiger Klassifikationsmethoden und ermöglicht es, die UDD-Klassifikation per edF-Vektorvergleich dort zu ergänzen, wo diese schlecht abschneidet. Auch der Rechenaufwand ist gering, was eine Echtzeitanwendung ermöglicht. Das Zeitverhältnis von Batchmessung zu Klassifikation beträgt im Durchschnitt 21.

Die statistische Varianz lässt sich durch die Ergebnisse des Gesamttests (Bild 7 unten) beschreiben. Hier variiert die Klassifikationsgenauigkeiten um maximal 1,8 Prozentpunkte. Dies ist auf die zufällige Aufteilung der Trainings- und Testdaten sowie die daraus resultierende Stabilitätszusammensetzung zurückzuführen. Die geringe Varianz dieser nichtdeterministischen Methoden verdeutlicht, dass UDD-Merkmale gut geeignet sind, Ratterschwingungen zu erkennen.

## 5.3 Bildklassifikation mittels NN und X-Y-Verlagerung

Der Input der Bildklassifikation mittels NN basiert auf der errechneten Verlagerung in der Hauptbearbeitungsebene (X-Y-Ebene). Es handelt sich um ein zweidimensionales

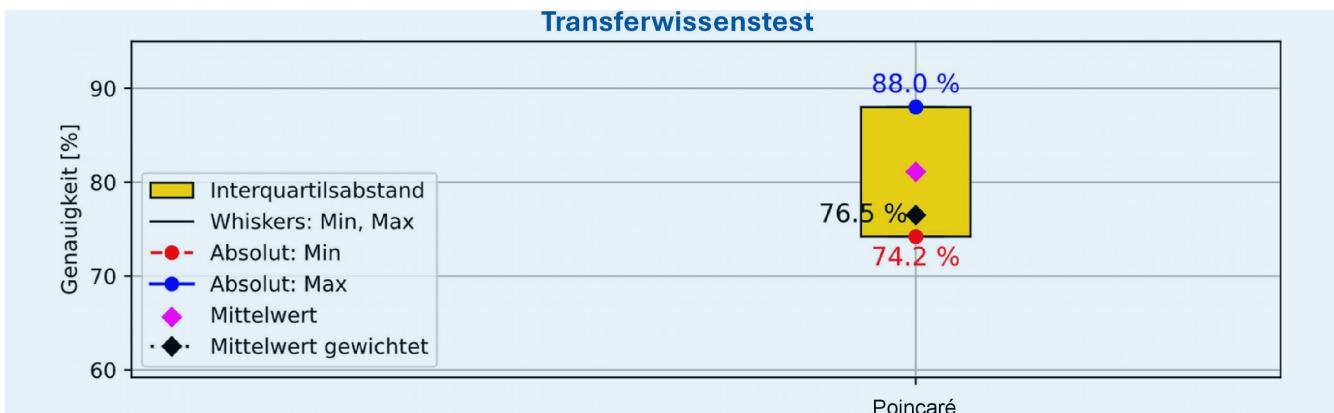


Bild 7. ML-Klassifikation auf Basis von UDD-Merkmalen. Grafik: WZL

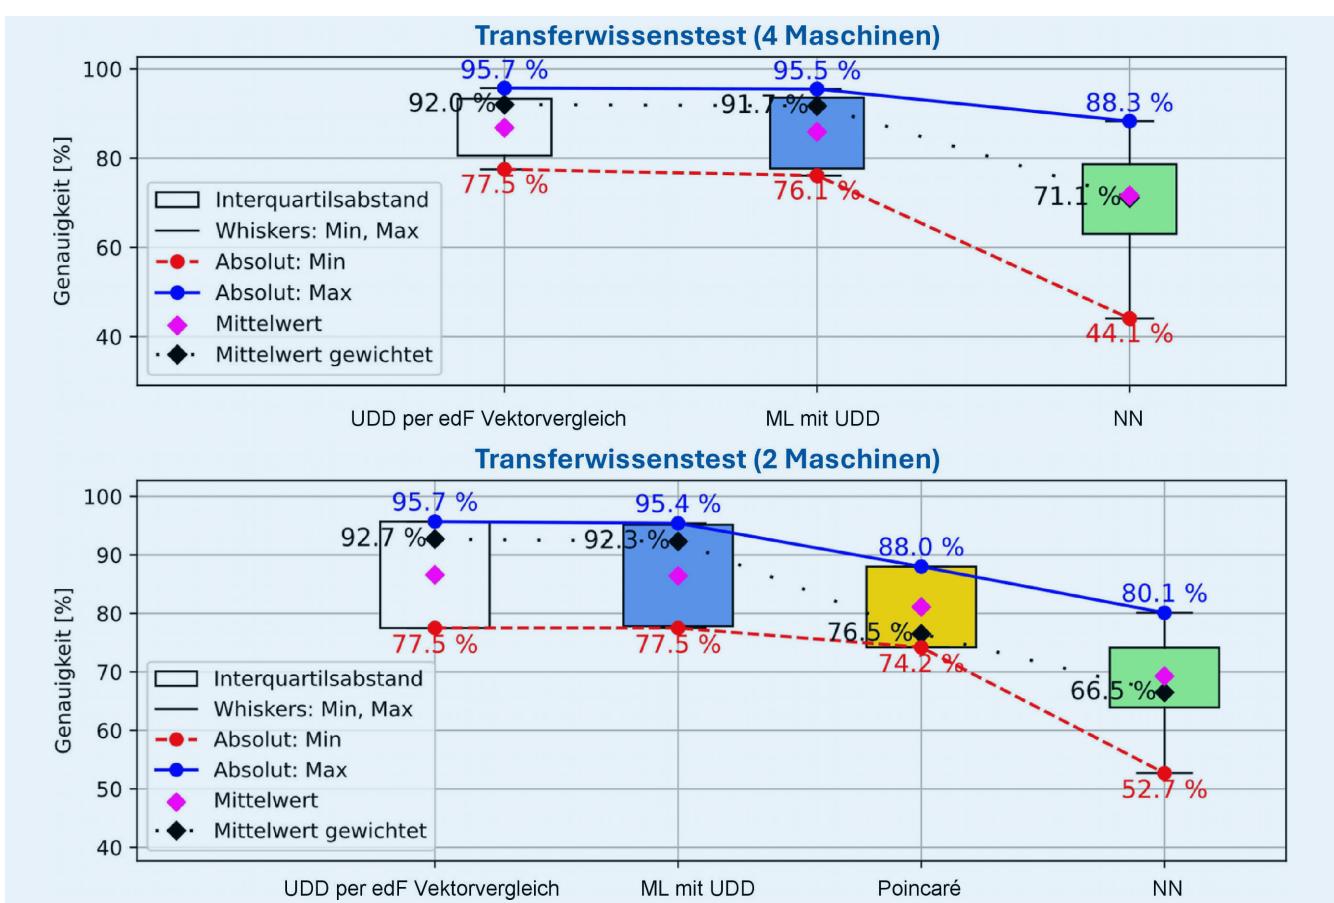


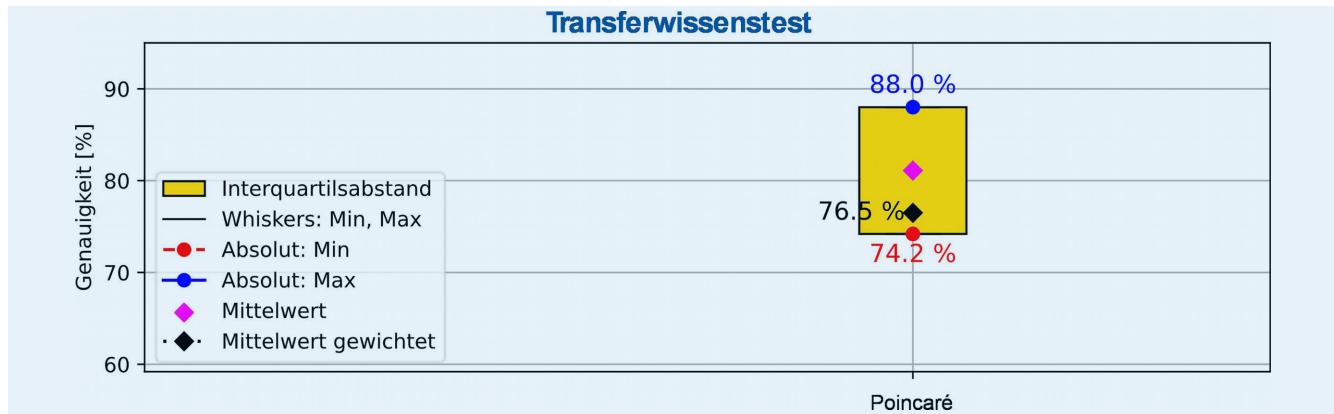
Bild 8. NN-Klassifikation auf Basis von 64x64 Pixel großen Verlagerungsbildern. Grafik: WZL

64x64-Pixel-Bild der Verlagerung, welches von einem NN auf Stabilität bewertet wird.

In Bild 8 werden zwei Klassifikationsmethoden miteinander verglichen: VGG16 mit vier Faltungsschichten [25] und ein gewöhnliches Convolutional Neural Network (CNN) mit drei Faltungsschichten, als Referenzarchitektur mit geringer Komplexität. Mit VGG16 wird ein gewichteter Klassifikationsdurchschnitt von 75,4 % erreicht. Die geringere Klassifikationsgenauigkeit ist nicht nur auf die Transferwissenstestgruppen, sondern auch auf die insgesamt schlechtere Erlernung von Stabilitätszuständen im Vergleich zur ML-Klassifikation auf UDD-Basis zurückzuführen. Dies könnte sich durch zu aussageschwache Klassifi-

kationsinputs begründen. Durch weitere Verfeinerung und Erweiterung der Inputdaten könnte sich die Klassifikationsgenauigkeit durch NN in diesem Fall erhöhen.

Wie bei allen KI-Algorithmen hängt auch hier die Klassifikation stark von den Trainingsdaten ab und ist somit trainingsdatenabhängig. Ein weiterer Aspekt ist der leicht erhöhte Rechenaufwand. Dennoch bietet das Verfahren mit einem durchschnittlichen Batchzeit-zu-Klassifikationszeit-Verhältnis von 11 eine echtzeitfähige Anwendung. Ein Vorteil gegenüber der UDD-Klassifikation per edF-Vektorvergleich ist auch hier die Möglichkeit, mehrere Instabilitätsursachen zu berücksichtigen, da das NN statt vordefinierter Merkmale als Input, wie beispielsweise aus der



**Bild 9.** Poincaré-Grenzwertklassifikation. *Grafik: WZL*

UDD-Merkalsextraktion, relevante Instabilitätsmerkmale selbstständig aus den Bilddaten extrahiert.

Die Ergebnisse des Gesamttests in Bild 8 (unten) zeigen, dass die Zusammensetzung der Stabilitätsursachen in den Trainingsdaten für das NN entscheidend ist. Das VGG16-Modell scheint zwar besser im Erlernen von Instabilitätszuständen im Vergleich zum CNN zu sein, jedoch weist es eine größere Varianz im Vergleich zur ML-Klassifikation (Bild 7 unten) des Gesamttests auf. Dies deutet darauf hin, dass stabilitiesrelevante Informationen aus UDD-basierten Merkmalen leichter extrahiert werden können als aus einer reinen Bildklassifikation der Verlagerungsdarstellung. Da die Merkmale zur Instabilitätserkennung vom NN selbstständig identifiziert werden, eignet sich diese Methode nicht für die Kombination mit der maschinenunabhängigen UDD-Klassifikation per edF-Vektorvergleich. Bei der ML-Klassifikation hingegen müssen Merkmale manuell definiert werden, sodass gezielt solche Merkmale ausgewählt werden können, die die UDD-Klassifikation per edF-Vektorvergleich ergänzen – ein Ansatz, der bei der NN-Bildklassifikation auf diese Weise nicht möglich ist.

#### 5.4 Poincaré-Grenzwertklassifikation

Die hier verwendete Grenzwertmethode basiert auf der empirischen Ermittlung von maschinenindividuellen Grenzwerten. Bei der Überschreitung der ermittelten Grenzwerte klassifiziert diese deterministische Methode den Zustand als instabil. Sie basiert auf dem Poincaré-Ansatz [20]. Es wird eine gewichtete Durchschnittsgenauigkeit von 76,5 % erreicht (Bild 9). Diese Methode ist system- und prozessabhängig, erfordert jedoch kein Training und benötigt nur einen geringen Rechenaufwand.

Auch diese Methode kann ergänzend zur UDD-Klassifikation per edF-Vektorvergleich verwendet werden, da sie für Maschine A mit 88 % eine höhere Klassifikationsgenauigkeit im Vergleich zur UDD-Klassifikation für dieselbe Maschine (77,5 %) aufweist und somit ergänzend wirken kann. Ein Nachteil ist jedoch die initiale Festlegung der Grenzwerte, was die industrielle Anwendung erschwert. Dies könnte durch eine Transformation zur automatisierten Ermittlung der Grenzwerte verbessert werden. Wenn Daten über den Lebenszyklus einer Maschine aufgenommen werden, ermöglicht dies das automatisierte Labeln und kontinuierliche Trainieren grenzwertbasierter Rattererkennungsmethoden, indem die Grenzwerte numerisch optimiert werden, beispielsweise durch ML-Verfahren wie kNN oder SVM.

#### 5.5 Gesamtvergleich

Die jeweils besten Methoden der ML- und NN-Klassifikation lassen sich neben der UDD-Klassifikation per edF-Vektorvergleich in Bild 10 anhand des Transferwissenstests zusammenfassen. Hier schneiden die beiden UDD-basierten Methoden mit bis zu 92 % gewichteter Durchschnittsgenauigkeit besser ab als die NN-Bildklassifikation. Diese Ergebnisse basieren auf der Verwendung der Messungen aller vier Maschinen. Auch im Vergleich mit der Grenzwertmethode lässt sich ein klares Fazit ziehen: UDD-basierte Methoden schneiden im Transferwissen besser ab als die Poincaré-Methode und die Bildklassifikation. Da Grenzwerte für die Poincaré-Methode nur für zwei der vier Maschinen bekannt sind, werden in diesem Vergleich für die anderen drei Methoden ebenfalls nur die Messungen dieser beiden Maschinen verwendet.

### 6 Grenzen UDD-basierter Klassifikationsmethoden

Sobald die Periodendauer einer angeregten Ratterfrequenz größer als die Dauer für eine Spindelumdrehung ist, kann diese mittels FFT nicht mehr extrahiert werden. So ergibt sich eine drehzahlbedingte Grenze. Es ist beispielsweise nicht möglich, Ratterfrequenzen kleiner als 50 Hz für eine Drehzahl von 3 000 1/min oder Ratterfrequenzen kleiner als 200 Hz für eine Drehzahl von 12 000 1/min zu ermitteln. Diese linear verlaufende Grenze wird hinsichtlich aller klassifizierten Batches in 1,9 % der Fälle überschritten. Neben dieser Untergrenze existiert auch eine Obergrenze der UDD, die durch das Shannon-Theorem [26] bestimmt wird und von der Abtastrate der verwendeten Sensoren abhängt. Ein Sensor mit Abtastrate von 5 120 Hz kann maximal Ratterfrequenzen bis 2 560 Hz erfassen. Diese Grenze wird in den Messdaten nicht überschritten.

### 7 Zusammenfassung

Diese Arbeit zeigt die Umsetzbarkeit unterschiedlicher Klassifikationsalgorithmen zur onlinefähigen, system- und prozessübertragbaren Instabilitätserkennung in Fräsprozessen. Dabei werden zwei neue Klassifikationsmethoden entwickelt, die durchschnittliche Klassifikationsgenauigkeiten von 91,7 % beziehungsweise 92 % erreichen. Transferwissenstests belegen, dass Instabilitätszusammenhänge tatsächlich erlernt werden, anstatt Klassifikations-

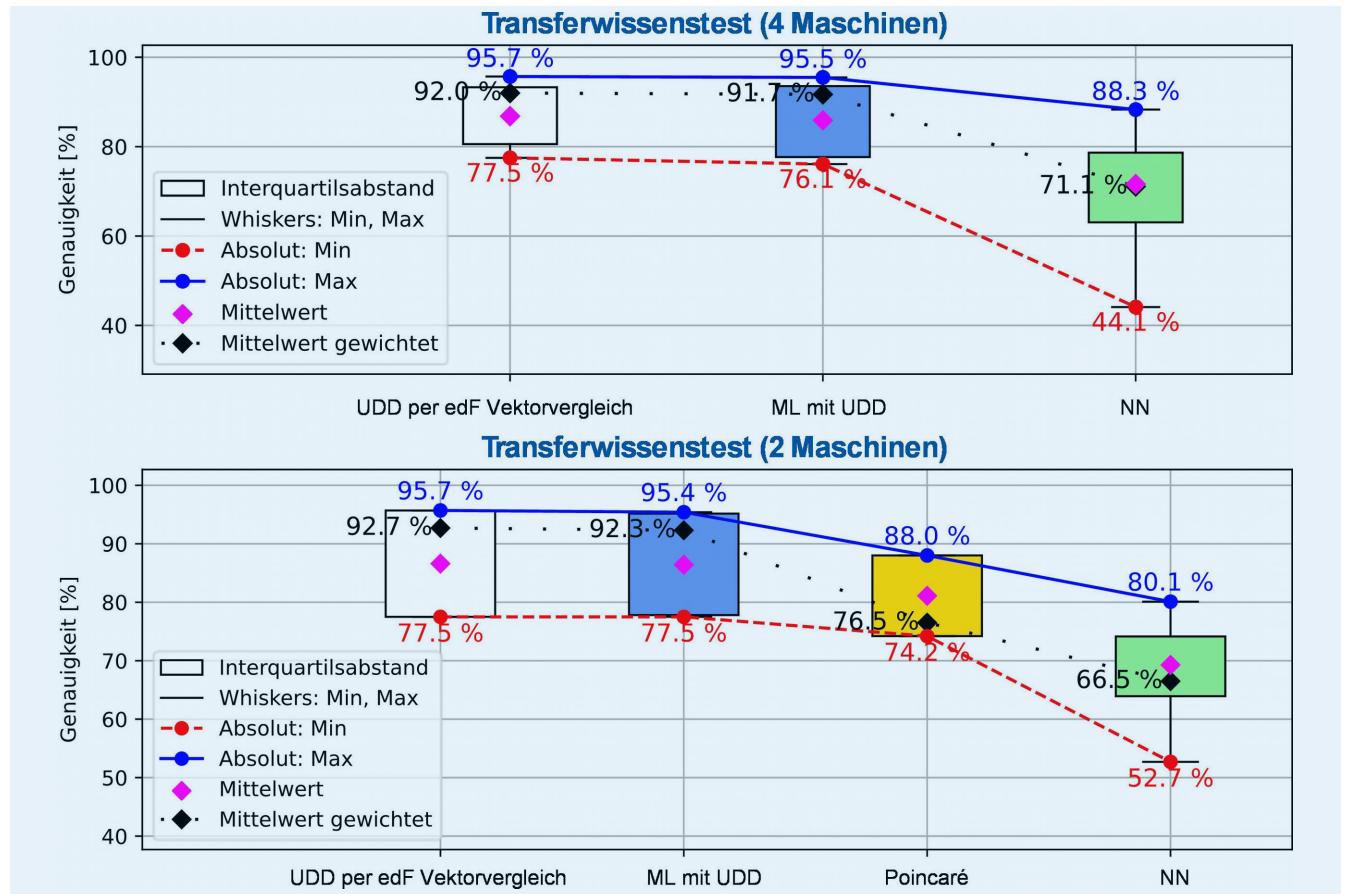


Bild 10. Gesamtvergleich der besten Klassifikationsmethoden. Grafik: WZL

aussagen anhand maschinenspezifischer Eigenschaften und Grenzwerten zu treffen.

Die entwickelte UDD-Klassifikation per edF-Vektorvergleich beweist, dass eine maschinunabhängige Klassifikation möglich ist und die Natur des Ratters durch die UDD mit hoher Erfolgsquote extrahiert wird. Alle hier vorgestellten Klassifikationsmethoden basieren auf einer einfachen Messkette, die Beschleunigungszustände und die Winkelposition der Spindel aus dem Fräsprozess verarbeitet. Dadurch wird eine praxisnahe Implementierung in der Industrie sichergestellt.

Zu den wesentlichen Errungenschaften zählen:

1. Die Erkenntnis, dass die Betrachtung mehrerer Maschinen-Werkzeug-Kombinationen für eine system- und prozessübergreifbare Rattererkennung notwendig ist.
2. Das Labeln von circa 5,6 Millionen Datenpunkten, die als Grundlage für eine umfassende Ratterdatenbank dient.
3. Die Entwicklung einer maschinunabhängigen Merkmalsextraktion (UDD), die eine robuste Klassifikation ermöglicht.
4. Die Entwicklung von zwei neuen UDD-basierten Klassifikationsmethoden, die Genauigkeiten von bis zu 96,4 % erreichen.
5. Die potenziell ergänzende Wirkung der UDD-Klassifikation per Vektorvergleich gegenüber grenzwert- beziehungsweise trainingsdatenabhängigen Methoden wie der ML-Klassifikation auf UDD-Basis.

Darüber hinaus wird gezeigt, dass die UDD-basierten Methoden sowohl nieder- als auch hochfrequentes Rattern zuverlässig erkennen.

Die UDD kann zudem als Querschnittstechnologie für verschiedene Anwendungen genutzt werden. Sie identifiziert dominante Schwingungen in der Nähe systemindividueller Eigenfrequenzen und eignet sich damit für Systeme mit rotierenden Maschinenelementen und dynamischer Krafteinwirkung. Neben Fräsprozessen könnten auch Verfahren wie Bohren und Drehen sowie Maschinen wie Turbinen potenzielle Anwendungsfelder darstellen.

Gerade im Kontext der E-Mobilität, in dem hohe Anforderungen an Präzision, Leichtbau und Bauteilkomplexität gestellt werden, eröffnet die vorgestellte onlinefähige Rattererkennung neue Möglichkeiten zur Optimierung zerspanender Fertigungsprozesse – etwa durch eine a-priori-Auslegung optimierter Prozessparameter oder eine Regelungsbasierte Prozessanpassung. Die zuverlässige Erkennung instabiler Zustände in Echtzeit schafft damit die Grundlage für eine konstant hohe Bearbeitungsqualität und kann zur Reduktion von Ausschuss und Maschinenstillständen beitragen. Darüber hinaus lassen sich Maschinen- und Werkzeugschäden verringern sowie Zeitspanvolumina erhöhen. Diese Eigenschaften stellen entscheidende Vorteile für die wirtschaftliche und skalierbare Produktion von Komponenten für elektrische Antriebssysteme dar.

## LITERATUR

- [1] Altintas, Y.; Brecher, C.; Weck, M. et al.: Virtual Machine Tool. *CIRP Annals* 54 (2005) 2, S. 115–138
- [2] Quintana, G.; Ciurana, J.: Chatter in machining processes: A review. *International Journal of Machine Tools and Manufacture* 51 (2011) 5, S. 363–376
- [3] Navarro-Davia, J.; Chen, Y.; Dao, D. et al.: Chatter detection in milling processes—a review on signal processing and condition classification. *The International Journal of Advanced Manufacturing Technology* 125 (2023) 9–10, S. 3943–3980
- [4] Brecher, C.; Chavan, P.; Epple, A.: Investigations on the limitations of rapid experimental determination of stability boundaries during milling. *Mechanics & Industry* 18 (2017) 6, S. 608
- [5] Ji, Y.; Wang, X.; Liu, Z. et al.: Early milling chatter identification by improved empirical mode decomposition and multi-indicator synthetic evaluation. *Journal of Sound and Vibration* 433 (2018), S. 138–159
- [6] Chen, Y.; Li, H.; Hou, L. et al.: Feature extraction using dominant frequency bands and time-frequency image analysis for chatter detection in milling. *Precision Engineering* 56 (2019), S. 235–245
- [7] Tran, M. Q.; Liu, M. K.: Chatter Identification in End Milling Process Based on Cutting Force Signal Processing. *IOP Conference Series: Materials Science and Engineering* 654 (2019) 1, S. 12001
- [8] Schmitz, T.; Smith, S.: *Machining Dynamics*. Cham: Springer International Publishing 2019
- [9] Liu, X.; Wang, Z.; Li, M. et al.: Feature extraction of milling chatter based on optimized variational mode decomposition and multi-scale permutation entropy. *The International Journal of Advanced Manufacturing Technology* 114 (2021) 9–10, S. 2849–2862
- [10] Tran, M.; Liu, M.; Tran, Q.: Analysis of Milling Chatter Vibration Based on Force Signal in Time Domain. In: Sattler, K.-U.; Nguyen, D. C.; Vu, N. P. et al. (Hrsg.): *Advances in Engineering Research and Application*. Cham: Springer International Publishing 2021, S. 192–199
- [11] Zhao, Y.; Adjallah, K.; Sava, A. et al.: MaxEnt feature-based reliability model method for real-time detection of early chatter in high-speed milling. *ISA transactions* 113 (2021), pp. 39–51
- [12] Chen, Y.; Li, H.; Hou, L. et al.: Chatter detection for milling using novel p-leader multifractal features. *Journal of Intelligent Manufacturing* 33 (2022) 1, S. 121–135
- [13] Hauptfleischová, B.; Novotný, L.; Falta, J. et al.: In-Process Chatter Detection in Milling: Comparison of the Robustness of Selected Entropy Methods. *Journal of Manufacturing and Materials Processing* 6 (2022) 5, S. 125
- [14] Perrelli, M.; Cosco, F.; Gagliardi, F. et al.: In-Process Chatter Detection Using Signal Analysis in Frequency and Time-Frequency Domain. *Machines* 10 (2022) 1, S. 24
- [15] Wang, Y.; Zhang, M.; Tang, X. et al.: A kMap optimized VMD-SVM model for milling chatter detection with an industrial robot. *Journal of Intelligent Manufacturing* 33 (2022) 5, S. 1483–1502
- [16] Xu, X.; Zhou, T.; Wan, L. et al.: Detection of modulated chatter using moving average difference spectrum analysis. *Journal of Sound and Vibration* 517 (2022), S. 116568
- [17] Zheng, Q.; Chen, G.; Jiao, A.: Chatter detection in milling process based on the combination of wavelet packet transform and PSO-SVM. *The International Journal of Advanced Manufacturing Technology* 120 (2022) 1–2, S. 1237–1251
- [18] Unver, H.; Sener, B.: A novel transfer learning framework for chatter detection using convolutional neural networks. *Journal of Intelligent Manufacturing* 34 (2023) 3, S. 1105–1124
- [19] Zhang, P.; Gao, D.; Hong, D. et al.: Improving generalisation and accuracy of on-line milling chatter detection via a novel hybrid deep convolutional neural network. *Mechanical Systems and Signal Processing* 193 (2023), S. 110241
- [20] Brecher, C.; Chavan, P.; Epple, A.: Efficient determination of stability lobe diagrams by in-process varying of spindle speed and cutting depth. *Advances in Manufacturing* 6 (2018) 3, S. 272–279
- [21] Garrett, S. L.: *The Simple Harmonic Oscillator*. In: Garrett, S. L. (Hrsg.): *Understanding Acoustics*. Cham: Springer International Publishing 2020, S. 59–131
- [22] Brecher, C.; Chavan, P.; Epple, A.: Investigations on the limitations of rapid experimental determination of stability boundaries during milling. *Mechanics & Industry* 18 (2017) 6, S. 608
- [23] Brecher, C.; Klimaschka, R.; Neus, S.: Effiziente Ermittlung dynamischer Prozessgrenzen/Efficient determination of dynamic process limits. *wt Werkstattstechnik online* 114 (2024) 05, S. 220–229
- [24] Reinhart, G.; Milberg, J.; Trucks, V.: *Rechnergestützte Beurteilung von Getriebestrukturen in Werkzeugmaschinen*. Berlin, Heidelberg: Springer Berlin Heidelberg 1996
- [25] Simonyan, K.; Zisserman, A.: *Very Deep Convolutional Networks for Large-Scale Image Recognition*, 2014
- [26] Brecher, C.; Weck, M.: *Werkzeugmaschinen, Fertigungssysteme*. Berlin, Heidelberg: Springer Vieweg 2017
- [27] Bosetti, P.; Leonesio, M.; Parenti, P.: On Development of an Optimal Control System for Real-time Process Optimization on Milling Machine Tools. *Procedia CIRP* 12 (2013), S. 31–36

Prof. Christian Brecher Ralph Klimaschka, M.Sc. Svante May, M.Sc. 

s.may@wzl.rwth-aachen.de

Dipl.-Ing. Stephan Neus Werkzeugmaschinenlabor WZL der RWTH Aachen  
Steinbachstr. 19, 52074 Aachen  
www.wzl.rwth-aachen.de

## LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons Namensnennung 4.0 International (CC BY 4.0)