

Akustische Überwachung des Werkzeugverschleißes bei der zerspanenden Bearbeitung

Christina Baumeister, Thomas Schlech, Marcel Achzet, Quy Raven Luong, Florian F. Linscheid, Bastian Brück, Markus G. R. Sause

Angaben zur Veröffentlichung / Publication details:

Baumeister, Christina, Thomas Schlech, Marcel Achzet, Quy Raven Luong, Florian F. Linscheid, Bastian Brück, and Markus G. R. Sause. 2023. "Akustische Überwachung des Werkzeugverschleißes bei der zerspanenden Bearbeitung." In *SCHALL 2023: Entwicklung und Anwendung der Schallemissionsanalyse und Zustandsüberwachung mit geführten Wellen*, 21./22. März 2023, Wetzlar. Berlin: DGZfP - Deutsche Gesellschaft für Zerstörungsfreie Prüfung e.V. <https://www.dgzfp.de/seminar/schall23>.

Nutzungsbedingungen / Terms of use:

CC BY 4.0

Akustische Überwachung des Werkzeugverschleißes bei der zerspanenden Bearbeitung

Christina BAUMEISTER¹, Thomas SCHLECH¹, Marcel ACHZET¹, Quy R. LUONG¹,
Florian F. LINSCHIED¹, Bastian BRÜCK¹, Markus G. R. SAUSE¹

¹ Universität Augsburg, Augsburg

Kontakt E-Mail: christina.baumeister@mrm.uni-augsburg.de

Kurzfassung. Ungefähr ein Fünftel der Maschinenausfälle in der Zerspanung sind werkzeugbedingt. Diese Ausfälle können durch den Einsatz geeigneter Prozess- und Zustandsüberwachungssysteme vermieden werden. Für die Überwachung zerspanender Prozesse können verschiedene Überwachungsstrategien und -systeme eingesetzt werden. Im Rahmen dieser Untersuchungen wird insbesondere der Einsatz von Körperschallsensorik analysiert, der Aufschluss über den Zustand des Werkzeugs liefern soll. Strategien zur Datenfusion werden mittels den aus den Rohdaten extrahierten Merkmalen untersucht. Die Datengrundlage, zur Erarbeitung von Diagnosemodellen, basierend auf Methoden des maschinellen Lernens, bilden praxisnahe Fallbeispiele für Bohr- und Fräsprozesse. Zur Erfassung der notwendigen Daten zur Bestimmung des Verschleißes eines Werkzeugs werden alle Versuche mittels Körperschallsensorik überwacht, während das Werkzeug kontinuierlich im Einsatz verschlissen wird. Als Grundlage der Untersuchungen wird je ein Regressionsmodell für die Überwachung der kontinuierlichen Abnutzung eines Werkzeugs bei einem Bohr- und bei einem Fräsprozess bei gleichbleibendem Material untersucht. Als nächster Schritt werden Modelle erstellt, die unterschiedliche metallische Materialien und den Einfluss von Variationen in den Prozessparametern berücksichtigen. Referenzwerte für die verschiedenen Regressionsmodelle bildet die Verschleißmarkenbreite, die den Zustand des Werkzeugs in Form des Werkzeugverschleißes beschreibt, welche mittels Lichtmikroskopie bestimmt wird.

1. Einführung

In produzierenden Unternehmen ist der Zustand des Werkzeugs bei der Zerspanung von großer Bedeutung, da dieser die Qualität des zu bearbeitenden Bauteils maßgeblich beeinflusst [1, 2]. Zudem sind etwa 20 % aller Maschinenausfälle werkzeugbedingt [1, 3]. Der ständige Gebrauch des Werkzeugs führt unweigerlich zum Verschleiß und resultiert daher in einer reduzierten Werkzeugeffektivität. Der Abnutungsgrad des Werkzeugs ist somit ein wesentlicher Aspekt zur Beschreibung des Zustands des Werkzeugs. Studien haben gezeigt, dass 70 % der gesamten Instandhaltungskosten auf den Kosten des Ersetzens verschlissener Komponenten beruhen [4, 5]. Um die Instandhaltungskosten mittels vorausschauender Wartung künftig zu senken, werden Zustands- und Prozessüberwachungssysteme erforscht.

In [6] wird die Wichtigkeit von Zustandsüberwachungslösungen für Maschinenbearbeitungsvorgänge bekräftigt. Mittels Zustandsüberwachungssystemen



können 10 – 40 % der Kosten durch Reduzierung von Maschinenausfallzeiten und durch die Verlängerung der Einsatzdauer der Werkzeuge gesenkt werden [1, 7].

Im Rahmen des Projekts SmartCut werden daher verschiedene Zustands- und Prozessüberwachungssysteme betrachtet. Hierzu wird die Überwachung von Bohr- und Fräsprozessen mittels eines Körperschallsensors, der in eine CNC Fräsmaschine integriert wird, präsentiert. Aus den erfassten Rohdaten werden mittels des MATLAB-basierten Softwareframeworks Ultra-High-Ultrasonic (UHU) [8, 9] Merkmale extrahiert und analysiert.

Da in der zerspanenden Bearbeitung viele Faktoren wie Qualität des Bauteils, Ausfallzeiten und Kosten vom Zustand des Werkzeugs abhängen, soll mittels der erfassten Daten des Körperschallsensors Aufschluss über den Werkzeugzustand gewonnen werden. Beim Zustand des Werkzeugs wird der Fokus auf das Verschleißerscheinungsbild gelegt. Um den Merkmalen ein Verschleißerscheinungsbild zuzuordnen, werden während der Versuche in regelmäßigen Abständen Lichtmikroskopiemessungen durchgeführt und die Verschleißmarkenbreiten bestimmt.

Zur Generierung einer Datenbasis wird das Werkzeug durch kontinuierlichen Einsatz beim Bohren und Fräsen sukzessive verschlissen. Die Verschleißmarkenbreite wird parallel dazu in regelmäßigen Abständen ermittelt, sodass den Messsignalen und den daraus extrahierten Merkmalen eine Verschleißmarkenbreite zugeordnet werden kann. Die Diagnose des Zustands, also die Zuordnung der Merkmale zu der entsprechenden Verschleißmarkenbreite erfolgt im Anschluss mit Hilfe von Regressionsmodellen des maschinellen Lernens. Dabei wird jeweils ein Modell, das die Daten des kontinuierlichen Verschleißversuchs in einem Chrom-Nickel Edelstahl beim Bohren und ein Modell für den Verschleiß bei einem Fräsprozess trainiert.

In [10] von Y. Zhou *et al.* ist eine Übersicht verschiedener Publikationen aufgelistet, die sich der Überwachung der Verschleißerscheinung verschiedener Werkzeuge in verschiedenen Materialien widmen. Dabei werden verschiedene Methoden von Klassifizierungs- und Regressionsmodellen untersucht. Diese analysieren analog zu dem in dieser Arbeit präsentierten Modell des Bohr- bzw. Fräsprozesses Einzelfälle, die sich auf ein Werkzeug und ein Material fokussieren. Zur Untersuchung der Generalisierbarkeit der Modelle des Bohr- bzw. Fräsprozesses wird im Folgenden ein Modell für Fräs- und eines für Bohrprozesse realisiert, deren Datenbasis sich über verschiedene Materialien wie einer Aluminium-, Edelstahl- und Titanlegierung sowie unterschiedliche Prozessparameter erstreckt.

Ziel ist es, ein Modell zu generieren, das nicht nur bei einem einzigen Material und einer spezifischen Einstellung der Prozessparameter den Werkzeugzustand zuordnen kann, sondern diesen unabhängig von Material- und Prozessparametern erkennt. Somit könnte eine Vorhersage des Werkzeugzustands generalisiert ermittelt werden und damit die Einsatzdauer der Werkzeuge verlängert bzw. frühzeitig verschlissene Werkzeuge ausgetauscht und die Bauteilqualität gewährleistet werden.

2. Material und Methoden

2.1 Versuchsdurchführung

Ein Körperschallsensor vom Typ Fujicera 1045S (Fuji Co.) wird in der z-Achse einer OPTImill® F80 (Optimum® GmbH) CNC Fräsmaschine in einer additiv gefertigten Halterung mittels Magnethaltern befestigt. Die Position des Körperschallsensors im Gehäuse oberhalb der Spindel bietet den Vorteil, dass die Distanz zwischen der Schallquelle, in diesem Fall der Eingriff des Werkzeugs, und dem Körperschallsensor über den

Bearbeitungszeitraum konstant bleibt. Eine schematische Darstellung der Position des Körperschallsensors sowie des Versuchsaufbaus ist in Abbildung 1 zu sehen.




Abbildung 1 Schematische Darstellung des Versuchsaufbaus

Der Körperschallsensor wird zusammen mit einem Zweikanal-Transientenrekorder ProSystem (BCMtec GmbH) in Verbindung mit der Aufzeichnungs- und Analysesoftware PROfile Ultrasonic (BCMtec GmbH) verwendet. Die Abtastrate liegt bei 1 MHz.

Die Versuche werden in einer Platte der Edelstahllegierung X8CrNiS18-9, der Aluminiumlegierung AlZn5,5MgCu und der Titanlegierung TiAl6V4 durchgeführt. Bei den Bohrprozessen wird ein HSS-E-Spiralbohrer mit einem spitzen Winkel von 130° verwendet. Um den Werkzeugdurchmesser zu variieren, wird ein 8 mm und 3,5 mm Bohrer vom gleichen Typ der Firma Hoffmann Group (Artikelnummer 114500 [8 mm] und 114500 [3,5 mm]) herangezogen. Zudem wird der HOLEX Pro Steel VHM-Torusfräser der Firma Hoffmann Group mit einer TiAlN-Beschichtung, einem Durchmesser von 12 mm, einem Schneidenradius von 1 mm, einem Spiralwinkel von 38° und 4 Zähnen verwendet.


In den drei Materialien werden sowohl Verschleißreihen als auch Variationen der Prozessparameter durchgeführt. Mit dem Begriff Verschleißreihe wird hierbei der kontinuierliche Einsatz eines zunächst neuen Werkzeugs bezeichnet, bis dieses aufgrund zu hoher Verschleißerscheinungen nicht mehr nutzbar ist. Innerhalb einer Verschleißreihe werden die Prozessparameter konstant gehalten. Die Variationen der Prozessparameter beinhalten Versuche, bei denen die Schnittgeschwindigkeit, Vorschub sowie die Werkzeugdimension (der Durchmesser beim Bohren) und die Zustellung (Zustellbreite beim Fräsen) variiert wird. Als Parameterkombinationen werden verschiedene Optimierungsziele für die Zerspanungsprozesse festgesetzt: *Optimales Zeitspanvolumen*, *Optimale Qualität*, *Optimaler Betriebspunkt* und *Verschleißoptimiert*. Die gewählten Prozessparameter sind in Tabelle 1 dargestellt. Bei den Bohrprozessen werden Durchgangsbohrungen durch eine 15 mm dicke Platte durchgeführt. Die Platte, die bei den Fräsversuchen verwendet wird, ist 30 mm dick. Dabei beträgt die Zustelltiefe der Fräsprozesse $a_p = 15$ mm. Die Zustellbreite wird bei den Verschleißreihen auf $a_e = 4$ mm und bei den Variationen der Prozessparameter auf $a_e = 0,2$ mm und $a_e = 0,5$ mm gesetzt.

Um den Verschleiß während der Versuche zu ermitteln, werden die Schneiden unter dem digitalen Mikroskop VHX – 6000 (KEYENCE DEUTSCHLAND GmbH) erfasst und dabei die Verschleißmarkenbreite bestimmt. Ein Beispiel der Betrachtung der Verschleißerscheinung unter dem Mikroskop ist in Abbildung 2 dargestellt. Abbildung 2a) zeigt die Entwicklung einer Schneide des 8 mm Bohrers und Abbildung 2b) die einer Schneide des 12 mm Fräasers, während einer Verschleißreihe in einer Platte der Edelstahllegierung X8CrNiS18-9. Die Variationen der Prozessparameter werden jeweils unter Verwendung eines neuen und eines verschlissenen Werkzeugs durchgeführt.

Tabelle 1 Übersicht der variierten Prozessparameter bei Bohr- und Fräsprozessen, Materialien der Werkstücke, Optimierungsziele, Schnittgeschwindigkeit v_c , Vorschub f , Durchmesser der Bohrer $\varnothing$ (beim Fräsen wird durchgehend ein Werkzeug mit einem Durchmesser von 12 mm verwendet), Zustellbreite a_e

Zerspanprozess		Bohren			Fräsen		
Materialien	Optimierungsziel	v_c (m/min)	f (mm/U)	$\varnothing$ (mm)	v_c (m/min)	f (mm/Z)	a_e (mm)
X8CrNiS18-9	Verschleißreihe	23	0,06	8	188,5	0,01125	4
X8CrNiS18-9	Optimale Parameter	19	0,09	8	82	0,07	0,2
X8CrNiS18-9	Zeitspanvolumen	23	0,11	8	90	0,08	0,2
X8CrNiS18-9	Qualität	19	0,07	8	82	0,05	0,2
X8CrNiS18-9	Verschleißreduktion	15	0,11	8	70	0,08	0,2
X8CrNiS18-9	Verschleißreihe	27	0,01	3,5	-	-	-
X8CrNiS18-9	Optimale Parameter	19	0,02	3,5	82	0,07	0,5
X8CrNiS18-9	Zeitspanvolumen	27	0,025	3,5	90	0,08	0,5
X8CrNiS18-9	Qualität	19	0,01	3,5	82	0,05	0,5
X8CrNiS18-9	Verschleißreduktion	15	0,025	3,5	70	0,08	0,5
AlZn5,5MgCu	Verschleißreihe	95	0,06	8	-	-	-
AlZn5,5MgCu	Optimale Parameter	75	0,2	8	260	0,28	0,2
AlZn5,5MgCu	Zeitspanvolumen	85	0,22	8	290	0,3	0,2
AlZn5,5MgCu	Qualität	85	0,16	8	260	0,24	0,2
AlZn5,5MgCu	Verschleißreduktion	65	0,22	8	230	0,3	0,2
AlZn5,5MgCu	Verschleißreihe	95	0,01	3,5	-	-	-
AlZn5,5MgCu	Optimale Parameter	75	0,06	3,5	260	0,28	0,5
AlZn5,5MgCu	Zeitspanvolumen	85	0,1	3,5	290	0,3	0,5
AlZn5,5MgCu	Qualität	85	0,03	3,5	260	0,24	0,5
AlZn5,5MgCu	Verschleißreduktion	65	0,1	3,5	230	0,3	0,5
TiAl6V4	Verschleißreihe	9	0,06	8	140	0,06	4
TiAl6V4	Optimale Parameter	6	0,09	8	65	0,06	0,2
TiAl6V4	Zeitspanvolumen	8	0,1	8	70	0,07	0,2
TiAl6V4	Qualität	6	0,06	8	65	0,05	0,2
TiAl6V4	Verschleißreduktion	5	0,1	8	55	0,07	0,2
TiAl6V4	Optimale Parameter	-	-	-	65	0,06	0,5
TiAl6V4	Zeitspanvolumen	-	-	-	70	0,07	0,5
TiAl6V4	Qualität	-	-	-	65	0,05	0,5
TiAl6V4	Verschleißreduktion	-	-	-	55	0,07	0,5

a)



b)




Abbildung 2 Entwicklung des Verschleißes bei kontinuierlicher Verwendung des a) 8 mm Bohrers nach einer entsprechenden Anzahl an Bohrungen und des b) 12 mm Fräasers nach einer entsprechenden Fräsbahnlänge in einer Platte der Edelstahllegierung X8CrNiS18-9

2.2 Vorgehen zur Datenverarbeitung

Die durch den Körperschallsensor aufgenommenen Rohdaten werden verarbeitet, um anschließend typische Signalcharakteristika bzw. Merkmale zu extrahieren. Mittels Regressionsmodellen des maschinellen Lernens werden diese Merkmale auf eine Verschleißmarkenbreite antrainiert.

Für die Vorverarbeitung werden mit Hilfe von Tief- und Hochpassfiltern zunächst Störgeräusche, wie beispielsweise Schwingungen des Spindelmotors, herausgefiltert. Somit können in den relevanten Zeitabschnitten, in denen ein Zerspanprozess stattfindet, aussagefähigere Merkmale berechnet werden. Ein Beispiel dafür, dass durch die Anwendung von Filtern das Signal des Spindelmotors eliminiert und somit der Bohrprozess deutlicher erkennbar ist, ist in Abbildung 3 zu sehen. Abbildung 3a) zeigt das originale ungefilterte Signal einer Bohrung, wobei aufgrund des durchgehend überlagerten Störsignals des Spindelmotors nicht zu erkennen ist, zu welchen Zeitabschnitten diese Bohrung stattfindet. In Abbildung 3b) wird ein Filter verwendet, der das Signal des Spindelmotors herausfiltert. Hierfür wird auf das Rohsignal ein Tiefpassfilter mit einer Durchlassfrequenz von 8 kHz und einer Sperrfrequenz von 10 kHz und anschließend ein Hochpassfilter mit einer Sperrfrequenz von 0,2 kHz und einer Durchlassfrequenz von 0,5 kHz angewandt. Bei dem gefilterten Signal ist ersichtlich, dass die Bohrung bei ca. 5 s beginnt. Bei genauerer Betrachtung ist auch zu erkennen, dass die Bohrung bei ca. 8 s, 11 s, 13 s und 16 s kurz stoppt. Dies ist prozessbedingt und legt damit eine hohe Sensitivität der Körperschallanalyse nahe.




Abbildung 3 a) Ungefiltertes und b) gefiltertes Signal eines Bohrvorgangs

Um die Merkmale aus den gefilterten Signalen zu erhalten, in denen ein Zerspanprozess stattfindet, werden die relevanten Zeitabschnitte ermittelt. Hierzu wird ein Schwellwertverfahren angewendet. Da während den Versuchen noch ein Beschleunigungssensor sowie ein sensorischer Werkzeughalter zur Messung von Kräften und Momenten herangezogen wird, wird das Schwellwertverfahren an dem jeweiligen Sensor durchgeführt, dessen Signaldifferenz bei dem jeweiligen Zerspanprozess den größten Unterschied zum Leerlauf aufweist und der Zerspanprozess somit eindeutig identifiziert werden kann. Durch die Synchronisation der Zeiten der Messdateien aller verwendeten Sensoren, liegen die Zeitabschnitte bei allen Sensoren und Versuchen vor, in denen ein Zerspanvorgang stattfindet. In Abbildung 4 sind die Körperschallsignale in dunkelgrün von sechs Bohrungen dargestellt. Die ermittelten Zeitabschnitte in denen ein Zerspanprozess vorliegt, sind hellgrün hinterlegt.

Die extrahierten Zeitabschnitte, in denen ein Zerspanvorgang stattfindet, werden weiterhin in diskrete 10 ms Intervalle unterteilt. Für diese Zeitintervalle werden folgende Merkmale berechnet: maximale Amplitude, maximale Amplitude im Frequenzraum, mittlere Frequenz, gewichtete maximale Amplitude im Frequenzraum, spektrale Leistungsdichte, Effektivwert (RMS), Durchschnittliche Amplitude, Geometrischer Mittelwert und




Abbildung 4 Gefiltertes Signal eines Körperschallsensors von sechs Bohrungen in dunkelgrün und Darstellung der ermittelten relevanten Zeitabschnitte, in denen ein Zerspanprozess stattfindet, in hellgrün

Standardabweichung [11]. Beim Bohren wird für jedes Bohrloch ein Durchschnittswert dieser Merkmale im Zeitraum der Bohrung berechnet. Beim Fräsen wird der Durchschnittswert der Merkmale über einen Zeitraum von 500 ms mit einem Überlapp von 250 ms als gleitender Mittelwert berechnet.

2.3 Regressionsmodelle des maschinellen Lernens

Für alle Merkmale wurde im ersten Schritt ein Versuch unternommen, einen analytischen Zusammenhang zwischen bestimmten Merkmalen und der Verschleißmarkenbreite herzustellen. Da sich jedoch keines der untersuchten Merkmale als stabil genug herausstellte, werden im zweiten Schritt verschiedene Regressionsmodelle des maschinellen Lernens untersucht. Dabei wird zunächst der gesamte Datensatz in Trainings- und Testdaten unterteilt. Von dem gesamten Datensatz wird jeder dritte Datenpunkt zu den Testdaten zugeordnet und der Rest als Trainingsdaten verwendet. Mittels der Trainingsdaten wird ein Regressionsmodell trainiert. Dabei werden Zusammenhänge und Muster erschlossen, d.h. es wird eine Verbindung erstellt, wie sich verschiedene Prozessparameter, wie z. B. Material, Schnittgeschwindigkeit, Vorschub usw. auf die extrahierten Merkmale auswirken und eine Verbindung zur Verschleißmarkenbreite geschaffen. Mittels der Testdaten wird die Güte des trainierten Modells auf unbekannten Daten ermittelt.

Dabei werden folgende Regressionsmodelle betrachtet: Support Vector Regression, Gaussian Process Regression, Ensemble Modelle und Neuronale Netze. In diesen Untersuchungen schneiden die Ensemble Modelle am besten ab, weshalb auf diese näher eingegangen wird. Das Ensemble Learning wird als ein Prozess definiert, das durch die Verwendung eines Kollektivs an Modellen (einem Ensemble) durch Kombination eine finale Vorhersage ermöglicht [12]. Dabei wird auch die Eignung von Ensemble-Modellen als Regressionsmodelle bewiesen [12]. Bei den Ensemble-Modellen wird unter anderem zwischen den Ensemble Learning Prinzipien *Bagging* und *Boosting* unterschieden. Boosting [13] beruht auf dem Prinzip mehrerer abhängiger Modelle. Die Daten beim Boosting werden gewichtet. Beim Trainieren eines Modells werden die Ergebnisse des Modells an das nächste Modell weitergegeben, sodass vorherige Ergebnisse mitberücksichtigt und die Gewichtung der Daten in den darauffolgenden Modellen angepasst wird. Falsch vorhergesagte Werte werden stärker gewichtet, um kritische Punkte hervorzuheben. Jedes Modell versucht den Fehler seines Vorgängers zu minimieren. Somit ist dieses Prinzip sensitiv gegenüber Ausreißern. Bei dem Ensemble Learning Prinzip Bagging [14] werden mehrere Modelle parallel und unabhängig voneinander mit dem gleichen Algorithmus, aber unterschiedlicher Teile des gesamten Datensatzes trainiert. Ein Vorteil von Bagging ist, dass eine sogenannte Überanpassung verhindert wird. Ein Nachteil

von Bagging hingegen ist, dass keines der Modelle den gesamten Datensatz erhält, sodass es vorkommen kann, dass ein Teil der Trainingsdaten in keinem der Modelle verwendet wird.

Im Rahmen dieser Untersuchung wird versucht, die Verschleißmarkenbreite aus den jeweiligen Merkmalen in vier immer anspruchsvolleren Situationen mittels Regressionsmodellen zu berechnen. Hierzu wird die Datenbasis systematisch erweitert, diese ist in Tabelle 2 aufgelistet. Die vier betrachteten Situationen werden dabei mittels der Modell-Nr. 1-4 gekennzeichnet.

Tabelle 2 Datenbasis der vier betrachteten Situationen, bei denen die Verschleißmarkenbreite mittels Regressionsmodellen zugeordnet wird mit den Modell-Nr. 1-4

Modell-Nr.	Zerspanungsstrategie	Zerspanprozess	Werkzeug	Material
1	Verschleißreihe	Bohren	8 mm HSS-E Spiralbohrer (Hoffmann Group)	X8CrNiS18-9
2	Verschleißreihe	Fräsen	12 mm VHM-Torusfräser (Hoffmann Group)	X8CrNiS18-9
3	Verschleißreihe und Parametervariation	Bohren	8 mm und 3,5 mm HSS-E Spiralbohrer (Hoffmann Group)	X8CrNiS18-9, AlZn5,5MgCu, TiAl6V4
4	Verschleißreihe und Parametervariation	Fräsen	12 mm VHM-Torusfräser (Hoffmann Group)	X8CrNiS18-9, AlZn5,5MgCu, TiAl6V4

Zu den in Abschnitt 2.2 erwähnten Merkmalen, die in dem ersten und zweiten Modell als Eingabewerte verwendet werden, werden im dritten und vierten Modell zusätzlich die Informationen über das Material, die Schnittgeschwindigkeit, den Vorschub, den Werkzeugdurchmesser beim Bohren und die Zustelltiefe beim Fräsen als Eingabedaten herangezogen.

Für die oben genannten Daten, die in den Modellen 1–4 fusioniert werden, wird getestet, welches Regressionsmodell jeweils das beste Ergebnis liefert. Dabei werden Support Vector Regression, Gaussian Process Regression, Ensemble Modelle und Neuronale Netze getestet. Der Root Mean Square Error $RMSE$ und das Bestimmtheitsmaß R^2 werden hierbei als Qualitätsmerkmale herangezogen. Das Bestimmtheitsmaß wird aus einem linearen Fit der Verschleißmarkenbreite, die mittels der trainierten Regressionsmodelle vorhergesagt wird, über die gemessenen Verschleißmarkenbreiten der Testdaten ermittelt. Der lineare Fit wird dabei durch den Nullpunkt gezwungen, da die Annahme zu Grunde gelegt wird, dass ein neues Werkzeug eine feste Verschleißmarkenbreite Null aufweist. Das Bestimmtheitsmaß R^2 gibt hierbei an, wie gut der durch die Regressionsmodelle vorhergesagte Wert dem tatsächlichen Wert entspricht. Dabei kann R^2 Werte von 0 bis 1 annehmen, wobei $R^2 = 1$ einer optimalen Vorhersage entspricht.

3. Ergebnisse und Diskussion

3.1 Zerspanen in Edelstahl

Zunächst wird jeweils ein Bohrprozess (Modell-Nr. 1) und ein Fräsprozess (Modell-Nr. 2) betrachtet, bei denen das Werkzeug kontinuierlich beim Einsatz verschlissen wird. Ein Modell des maschinellen Lernens dient dazu, aus den Merkmalen die jeweilige Verschleißmarkenbreite zu berechnen.




Abbildung 5 a) Tatsächliche (orange) und durch das Boosted Ensemble Tree Modell vorhergesagte (dunkelgrün) Verschleißmarkenbreite VB beim kontinuierlichen Einsatz des 8 mm Bohrers. b) Durch das Boosted Ensemble-Modell vorhergesagte Verschleißmarkenbreite im Vergleich zur gemessenen Verschleißmarkenbreite beim Bohren. Die hellgrüne Einheitsgerade entspricht einer idealen Vorhersage

Die Daten, die während des kontinuierlichen Einsatzes der Werkzeuge erfasst werden, werden verarbeitet und die entsprechenden Merkmale extrahiert, wie in Abschnitt 2.2 beschrieben. Mit diesen Merkmalen wird ein Boosted Ensemble Tree Modell gegen die Verschleißmarkenbreite mittels der Trainingsdaten trainiert. In Abbildung 5a) sind die tatsächlichen Messpunkte der Verschleißmarkenbreite VB beim Bohren als orangene Punkte gekennzeichnet. Zwischen den gemessenen Punkten werden die Werte interpoliert. Die durch das Ensemble-Modell vorhergesagte Verschleißmarkenbreite VB der Testdaten sind in dunkelgrün als Funktion der Bohrungsnummer dargestellt. Trotz der Auftragung in Abhängigkeit der Bohrungsnummer werden die Bohrungsnummern nicht als Eingabewerte des Modells verwendet. In Abbildung 6a) sind die Testdaten analog für den Fräsprozess aufgetragen. Der Index beschreibt jeweils ein Zeitintervall von 500 ms in denen der Durchschnitt der Merkmale mit einem Überlapp von 250 ms berechnet wird. Der Index wird ebenfalls nicht als Eingabewert verwendet. Es ist in Abbildung 5a) und Abbildung 6a) zu erkennen, dass die vorhergesagten Werte in dunkelgrün innerhalb des Messfehlers, der durch die orangenen Fehlerbalken dargestellt ist, liegen. Der Messfehler entsteht bei der Ermittlung der Verschleißmarkenbreite unter dem Mikroskop und beträgt ca. 0,01 mm. In Abbildung 5b) und Abbildung 6b) ist ersichtlich, dass sich die vorhergesagte Verschleißmarkenbreite in Abhängigkeit der gemessenen Verschleißmarkenbreite der Einheitsgeraden in hellgrün annähert. Verglichen mit den anderen Herangehensweisen über Support Vector Regression, Gaussian Process Regression, Ensemble Modellen und Neuronalen Netzen, schneidet das gezeigte Boosted Ensemble Tree Modell (siehe Abbildung 5) beim Bohren am besten ab.




Abbildung 6 a) Tatsächliche (orange) und durch das Boosted Ensemble Tree Modell vorhergesagte (dunkelgrün) Verschleißmarkenbreite VB beim kontinuierlichen Einsatz des Fräasers. Der Index beschreibt jeweils ein Zeitintervall von 500 ms in denen der Durchschnitt der Merkmale mit einem Überlapp von 250 ms berechnet wird. b) Durch das Boosted Ensemble-Modell vorhergesagte Verschleißmarkenbreite im Vergleich zur gemessenen Verschleißmarkenbreite beim Fräsen. Die hellgrüne Einheitsgerade entspricht einer idealen Vorhersage

Beim Fräsen liefern das Boosted Ensemble Tree Modell und das Bagged Ensemble Tree Modell die gleiche Qualität. Das Boosted Ensemble Tree Modell mit einem Bestimmtheitsmaß von $R^2 = 0,993$ und einem Root Mean Square Error von $RMSE = 0,008$ mm übertrifft beim Bohren das Bagged Ensemble Modell mit $R^2 = 0,991$ und $RMSE = 0,009$ mm. Andere Modelle, wie z. B. das Gaussian Process Regression Modell mit $R^2 = 0,992$ und $RMSE = 0,009$ mm liefern ähnliche Ergebnisse. Beim Fräsen weisen beide Ensemble Modelle $R^2 = 0,997$ und $RMSE = 0,003$ mm auf. Wird berücksichtigt, dass ein Bestimmtheitsmaß von $R^2 = 1$ einer optimalen Vorhersage entspricht und der Messfehler der Verschleißmarkenbreite ca. 0,01 mm beträgt, liefern die Ensemble Modelle sehr gute Ergebnisse. Das Boosted Ensemble Modell schneidet beim Bohren am besten ab und weist beim Fräsen und Bohren die geringste Streuung auf, jedoch sind andere Modelle ebenfalls gut geeignet, da sich die Ergebnisse nur marginal unterscheiden.

3.2 Kombination von Materialien und Prozessparametern

In diesem Abschnitt wird jeweils ein Modell für Bohrprozesse (Modell-Nr. 3) und eines für Fräsprozesse (Modell-Nr. 4) untersucht. Als Datenbasis werden Versuche herangezogen, bei denen das Werkzeug kontinuierlich abgenutzt wird und die Prozessparameter variiert werden. Dabei werden die unterschiedlichen Prozessparameter jeweils mit einem neuen und einem im Rahmen der Verschleißreihen abgenutzten Werkzeug durchgeführt. Zudem werden die Daten für eine Aluminium-, Edelstahl- und Titanlegierung erhoben.

Werden verschiedene Herangehensweisen über Support Vector Regression, Gaussian Process Regression, Ensemble Modellen und Neuronalen Netzen verglichen, weisen die Ensemble Modelle sowohl beim Bohren als auch beim Fräsen das beste Ergebnis auf. Dabei schneiden das Bagged Ensemble Tree Modell und das Boosted Ensemble Tree Modell annähernd gleich ab. Bei den Bohrprozessen übertrifft das Boosted Ensemble Tree Modell mit einem Bestimmtheitsmaß von $R^2 = 0,959$ nur marginal das Bagged Ensemble Tree Modell mit $R^2 = 0,952$. Beide Modelle weisen den gleichen Root Mean Square Error von $RMSE = 0,012$ mm auf. Beim Fräsen werden bei beiden Modellen die gleichen Werte von $R^2 = 0,993$ und $RMSE = 0,005$ mm ermittelt. Dieses Ergebnis führt zu der Schlussfolgerung, dass parallel und sequenziell geschaltete Modelle keinen großen Unterschied bei den vorliegenden Daten machen. Somit sind sowohl Bagged als auch Boosted Ensemble Tree Modelle geeignet.

Die durch den Einsatz der trainierten Modelle bestimmte Verschleißmarkenbreite der Testdaten im Vergleich zur gemessenen Verschleißmarkenbreite ist in Abbildung 7a) für den Bohrprozess und in Abbildung 7b) für den Fräsprozess dargestellt. Die Einheitsgerade in hellgrün zeigt die optimale Vorhersage als Referenz.




Abbildung 7 Darstellung der durch die Boosted Ensemble Tree Modelle vorhergesagten Verschleißmarkenbreite im Vergleich zur gemessenen Verschleißmarkenbreite bei a) Bohrprozessen und b) Fräsprozessen in verschiedenen Materialien und bei variierenden Prozessparametern. Die hellgrüne Einheitsgerade entspricht einer idealen Vorhersage

Für die Generalisierung der Bohr- und Fräsprozesse sind somit die Ensemble Modelle sehr gut geeignet. Trotz unterschiedlicher Materialien und Prozessparameter berechnen diese die Verschleißmarkenbreite sehr gut und streuen dabei geringer als andere Modelle. Trotz der global guten Ergebnisse sind in Abbildung 7a) und Abbildung 7b) einige Punkte erkennbar, die nahezu parallel zur y-Achse streuen. Ein Beispiel dafür ist bei der gemessenen Verschleißmarkenbreite $VB \approx 0,16$ mm zu sehen. Dies sind die Werte der Messungen, denen eine Variation der Prozessparameter Schnittgeschwindigkeit und Vorschub sowie Werkzeugradius beim Bohren und Zustellbreite beim Fräsen zugrunde liegen. Aufgrund einer zu geringen Datenbasis können hierbei die Zusammenhänge der wechselnden Parameter und der Verschleißmarkenbreite nicht so gut wie bei den Verschleißreihen mit konstanten Parametern festgestellt werden. Dies ließe sich jedoch iterativ durch Hinzunahme von mehr Datenpunkten verbessern.

4. Zusammenfassung

Die hier vorgestellten Ergebnisse verdeutlichen, dass anhand der Merkmale, die aus den gefilterten Signalen eines Körperschallsensors extrahiert werden, die Verschleißmarkenbreite von Zerspanungswerkzeugen mit Hilfe von Regressionsmodellen analysiert und zugeordnet werden kann. Dabei bewähren sich Boosted Ensemble Modelle bei den Bohrprozessen. Bei den untersuchten Fräsprozessen schneiden die Bagged Ensemble Modelle und die Boosted Ensemble Modelle gleich gut ab. Es wird gezeigt, dass sich die Ensemble Modelle sowohl für einzelne Bohr-/Fräsprozesse, bei denen die Körperschalldaten auf der kontinuierlichen Abnutzung des Werkzeugs mit konstanten Prozessparametern in einem Material basieren, als auch bei Hinzunahme der Daten aus mehreren Versuchen eignen. Dabei werden sowohl Materialien als auch Prozessparameter variiert. Es ist somit möglich, die Verschleißmarkenbreite mittels eines einzigen Modells für Bohr-/Fräsprozesse vorherzusagen, um unabhängig von der Wahl des Materials und den Prozessparameter auf Basis der Verschleißmarkenbreite einen kritischen Zustand des Werkzeugs zu ermitteln. Somit kann das Werkzeug bei einem fortgeschrittenen Verschleißerscheinungsbild frühzeitig vor einem statistisch festgesetzten Standzeitende gewechselt und so werkstückseitige Form- und Maßgenauigkeiten eingehalten sowie Ausschuss vermieden werden. Bei geringen Verschleißerscheinungen kann das Werkzeug länger als die Standzeit verwendet werden. Damit kann die Einsatzdauer der Werkzeuge individuell und unabhängig von Erfahrungswerten oder festen statistisch definierten Standzeiten angepasst werden. Dennoch besteht weiterhin Optimierungspotential, da teilweise Abschnitte einzelner Versuche nicht richtig zugeordnet werden. Mittels einer größeren Datenbasis kann dem jedoch entgegengewirkt werden.

Danksagung

Wir bedanken uns bei der Kompetenzzentrum Mittelstand GmbH für die Finanzierung im Rahmen des Projektes „SmartCut“. Zudem gilt unser Dank allen im Projekt involvierten Projektpartnern. Besonders herzlichen Dank an Sinan Kalafat (BCMtec GmbH) und Sebastian Gade (BCMtec GmbH) für die Beratung im Bereich Sensortechnologie und Data Science sowie für die Bereitstellung der Sensorik und der Messsoftware. Für die Realisierung von Messungen beim Bearbeiten von Titan und die Bereitstellung des Materials geht unser Dank an Dr. Matthias Lange (Premium AEROTEC GmbH).

Referenzen

- [1] Peng, Ruitao, et al. "Study of tool wear monitoring using machine vision." *Automatic Control and Computer Sciences* 54 (2020): 259-270.
- [2] Qiang, Li, et al. "Research on surface integrity in milling Inconel718 superalloy." *The International Journal of Advanced Manufacturing Technology* 92 (2017): 1449-1463.
- [3] Malekian, Mohammad, Simon S. Park, and Martin BG Jun. "Tool wear monitoring of micro-milling operations." *Journal of Materials Processing Technology* 209.10 (2009): 4903-4914.
- [4] Venkataraman, V. *Maintenance engineering and management*. PHI Learning Pvt. Ltd., 2010.
- [5] Mourtzis, Dimitris, et al. "48th CIRP Conference on Manufacturing systems-CIRP CMS 2015 A cloud-based approach for maintenance of machine tools and equipment based on shop-floor monitoring." *Procedia CIRP* 41 (2016): 655-660.
- [6] Teti, Roberto, et al. "Advanced monitoring of machining operations." *CIRP annals* 59.2 (2010): 717-739.
- [7] Fu, Pan, A. D. Hope, and G. A. King. *Intelligent tool condition monitoring in milling operation*. SOUTHAMPTON INST (UNITED KINGDOM) SYSTEMS ENGINEERING FACULTY, 1998.
- [8] Linscheid, F. F., Sause, M. G. R. "Hard- und Softwarefusion von mehreren akustischen Messmethoden zur Zustandsüberwachung." in DGZfP Jahrestagung 2021 (virtuell): Materialcharakterisierung, 10. - 11. Mai 2021. Deutsche Gesellschaft für Zerstörungsfreie Prüfung (DGZfP), Berlin, 1-8
- [9] Linscheid, F. F. *Entwicklung eines Zustandsüberwachungssystems durch Kombination von akustischen Überwachungsverfahren*. Dissertation, 2022, Universität Augsburg
- [10] Zhou, Yuqing, and Wei Xue. "Review of tool condition monitoring methods in milling processes." *The International Journal of Advanced Manufacturing Technology* 96 (2018): 2509-2523.
- [11] Sause, Markus G. R. *In situ monitoring of fiber-reinforced composites: theory, basic concepts, methods, and applications*. Vol. 242. Springer, 2016.
- [12] Mendes-Moreira, Joao, et al. "Ensemble approaches for regression: A survey." *Acm computing surveys (csur)* 45.1 (2012): 1-40.
- [13] Valiant, Leslie G. "A theory of the learnable." *Communications of the ACM* 27.11 (1984): 1134-1142.
- [14] Breiman, Leo. "Bagging predictors." *Machine learning* 24 (1996): 123-140.