

NUTZUNG VON METHODEN DES MASCHINELLEN LERNENS FÜR DIE WERKSTÜCKQUALITÄTS- UND WERKZEUGVERSCHLEISSÜBERWACHUNG BEI SEMI-AUTOMATISCHEN BOHRPROZESSEN

S. Junghans, D. Romanenko, W. Hintze

Institut für Produktionsmanagement und -technik, Technische Universität Hamburg (TUHH), Denickestraße 17, 21073 Hamburg, Deutschland

Zusammenfassung

Das Nieten von Strukturbauteilen erfordert im Flugzeugbau die Fertigung einer großen Anzahl von Nietbohrungen. Für jedes Bohrloch müssen Qualitätsstandards eingehalten werden, um Nacharbeiten und Ausschuss zu vermeiden. Daraus ergeben sich hohe Anforderungen an die Prozessstabilität und Qualitätsüberwachung beim Bohren. Die Fertigung von Nietbohrungen wird zunehmend mit elektrischen, semi-automatischen Bohrvorschubeinheiten (BVE) durchgeführt, wobei pneumatisch betriebene Maschinen ersetzt werden. Die elektrischen BVEs ermöglichen eine Ausstattung mit interner Sensorik, die eine Aufzeichnung von Antriebsströmen sowie Vibrationen der Maschinenstruktur ermöglicht. In dieser Arbeit werden die Prozessdaten hinsichtlich ihres Potentials zur Bestimmung des momentan vorherrschenden Werkzeugverschleißzustands und der resultierenden Werkstückqualität unter Anwendung von Methoden des maschinellen Lernens (ML) untersucht. Hierzu wurden Prozessdaten beim Bohren von TiAl6V4 und CFK in experimenteller Umgebung aufgenommen und mit der Hilfe von Skripten zur Datenverarbeitung in Matlab untersucht. Dabei wurde die Eignung ausgewählter Methoden zur Dimensionsreduktion für das Modelltraining im Hinblick auf eine Vorhersage von Werkzeugverschleiß und Werkstückqualität bestimmt. Relevante Merkmale konnten vor allem im Zeitbereich und im Zeit-Frequenz-Bereich der Wavelettransformation des Vorschubmotorstroms identifiziert werden. Sowohl für den Verschleiß als auch für die Qualität konnten auf Basis der herausgestellten Merkmale erfolgreich Vorhersagemodelle trainiert werden. Die Auswertung der Klassifikation und Regression zeigte eine gute Vorhersage des Werkzeugverschleißes durch Klassifikationsbäume sowie unregulärer und regulärer linearer Regression. Gute Vorhersagen der Qualität konnten für die Austrittsgrathöhe beim Bohren in TiAl6V4 und für die Delamination an der Austrittsseite beim Bohren in CFK erzielt werden. Die erzielten Ergebnisse bilden eine Grundlage für eine weiterführende Entwicklung von Methoden unter Einsatz des maschinellen Lernens in der Qualitätskontrolle beim Bohren.

Keywords

Strukturmontage; Qualitätsüberwachung; Nietverbindungen; Bohrtechnologien; Maschinelles Lernen

1. EINLEITUNG

Der Einsatz innovativer Leichtbauwerkstoffe und das Ziel der Gewichtsreduzierung im Flugzeugbau gehen mit der Entwicklung neuer Fügetechniken einher. Diese umfassen neben klassischen Nietverbindungen verschiedene Techniken zur Herstellung von Klebe- und Schweißverbindungen. Trotz Einsatz neuer Verfahren haben Nietverbindungen weiterhin einen hohen Anteil an allen durchgeführten Fügevorgängen in der Flugzeugstrukturmontage. Für den Airbus A350 XWB beläuft sich beispielsweise die Gesamtzahl der Nietverbindungen pro Flugzeug auf 230.000 Nieten [1]. Jede Nietverbindung erfordert wiederum die Fertigung einer Nietbohrung mit strengen Qualitätsvorgaben in der Luftfahrt.

Die COVID-19 Pandemie sorgte zeitweilig ab dem Jahr 2020 für einen großen Einschnitt der Zahlen im Luftverkehr. Unter Berücksichtigung der Pandemie hat das

Deutsche Zentrum für Luft- und Raumfahrt (DLR) zwei Szenarien zur Entwicklung des zivilen Luftverkehrs ausgearbeitet, die auf einem vom DLR entwickelten Prognosemodell basieren [2]. Das Szenario Low erwartet eine Auswirkung der Pandemie auf die langfristige Verkehrsentwicklung mit einem Wachstum des Passagieraufkommens von 2,8% pro Jahr bis zum Jahr 2040. Das optimistische Szenario High geht von 3,5% pro Jahr aus. Das resultiert in einem jährlichen weltweiten Aufkommen von 8,1 Mrd. bzw. 9,4 Mrd. Passagieren im Jahr 2040. Beide Fälle zeigen einen langfristigen Anstieg des Passagieraufkommens, dem die Fluggesellschaften mit einer Ausweitung ihrer Flotten und dem Einsatz von Flugzeugen mit höherer Kapazität begegnen müssen. Unter anderem erwartet Boeing bis 2042 einen weltweiten Mehrbedarf von mehr als 24.000 neuen Flugzeugen gegenüber dem Jahr 2022 [3]. Eine unmittelbare Folge aus der erhöhten Nachfrage ist eine für die Deckung notwendige Ratensteigerung in der Flugzeugherstellung durch eine Ausweitung des Produktionsvolumens. Dadurch resultiert parallel eine Zunahme der zu

fertigenden Nietbohrungen in der Flugzeugmontage innerhalb eines Jahres.

Die große Anzahl benötigter Bohrungen kann bei Qualitätsmängeln zu aufwendiger Nacharbeit und finanziellen Einbußen führen. Die Qualitätsanforderungen sind bedingt durch hohe Sicherheitsanforderungen, die für die Nieten Präzisionsbohrungen mit engen Toleranzen und hohen Oberflächengüten voraussetzen. Im Jahr 2014 wurden bei Airbus Bauabweichungen mit Kosten in Höhe von 400 Mio. Euro verursacht. Davon entfielen 50 % auf die Fertigung von Bohrungen [1]. Durch den Einsatz von geeigneten Methoden zur automatischen Überwachung der Bohrprozesse, können Qualitätsmängel und Abweichungen im Prozess frühzeitig erkannt werden. Darüber hinaus kann die Wirtschaftlichkeit des Prozesses insgesamt verbessert werden. Dies betrifft unter anderem den Werkzeugverschleiß, der einen maßgeblichen Einfluss auf den Bohrprozess hat. Die Werkzeuge werden häufig nach dem Überschreiten einer festgelegten Anzahl gefertigter Bohrungen (Standmenge) getauscht, wodurch eine vollständige Ausnutzung der Streuung individueller Standmengen einzelner Werkzeuge nicht gewährleistet ist. Durch die Prozessüberwachung lässt sich der individuell optimale Zeitpunkt zum Austausch eines Werkzeugs bestimmen. In der Vergangenheit konnten durch den Einsatz von Methoden zur Verschleißüberwachung bei der Drehbearbeitung von Guss- und Schmiedeteilen bereits 60% der anfallenden Werkzeugkosten eingespart werden [4].

Die Aufzeichnung von Prozessdaten während der Nietbohrprozesse stellt aufgrund ihrer hohen Anzahl und Wiederholbarkeit eine belastbare Datenbasis dar, die im Rahmen dieser Arbeit hinsichtlich ihres Potentials zur Nutzung für das Training von Vorhersagemodellen für den Werkzeugverschleiß und die Bohrungsqualität untersucht wird.

2. STAND DER TECHNIK

2.1. Bohrtechnologien im Flugzeugbau

Neben dem Kleben und Laserstrahlschweißen sind Nietverbindungen die am häufigsten anzutreffende Verbindungsart beim Fügen von Schalen- und Strukturbauteilen (z. B. Stringer und Spanten). Dabei nimmt die Fertigung der Nietbohrungen einen Großteil des Prozesses ein. Die hohe Anzahl der Bohrungen geht aufgrund hoher Anforderungen an die Qualität mit stetigen Kontrollen einher. Neben einer Justierung der Bauteile und dem Vor- und Aufbohren der Nietbohrung gehören das Entgraten sowie einzelne Prüf- und Reinigungsschritte vor dem eigentlichen Setzen der Nieten zum Gesamtablauf bei der Anfertigung einer Nietverbindung [5].

Beim Einsatz von Bohrmaschinen kommen verschiedene Prozessvarianten hinsichtlich ihrer Automatisierungsgrades zum Einsatz. Manuelle Bohrprozesse nutzen handgeführte Bohrmaschinen. Dabei werden die Positionierung, Ausrichtung und die Ausübung der Vorschubbewegung manuell vom Bediener vorgenommen. Sie kommen vor allem in Montageabschnitten zum Einsatz, in denen die Zugänglichkeit eingeschränkt ist [6]. Dem manuellen Prozess steht die Vollautomatisierung gegenüber. Hierbei werden die Bohrvorschubeinheiten (BVE) von

Industrierobotern als Endeffektor geführt. Bei der Fertigung der Landeklappen des Airbus A330 und A350 werden täglich bis zu 5.000 Nietbohrungen von Robotern gefertigt [7].

Zwischen den manuellen und vollautomatisierten Prozessen steht der Einsatz von semiautomatischen Bohrvorschubeinheiten. Während die Positionierung der Maschine manuell vom Bediener und optional unter Einsatz von lokalisierenden Assistenzsystemen vorgenommen wird, findet der Bohrvorgang in das Material automatisiert statt. Nach erfolgter Arretierung der Maschine in einer Schablone werden die Vorschubbewegung und weitere Maßnahmen zur Prozessführung, wie die Anpassung der Schnittparameter beim Bohren von Schichtverbunden, automatisch ausgeführt und geregelt. Elektronische Antriebseinheiten ermöglichen in diesem Zusammenhang den Einsatz zusätzlicher Sensorik innerhalb der Maschine. Die Folge daraus sind Möglichkeiten zur Überwachung des Bohrprozesses [8, 9]. BVEs dieser Art sind in vielen Fällen mit einem System zum vibrationsunterstützten Bohren (Peck-Feed-System) von metallischen Werkstoffen ausgestattet. Die Vorschubbewegung wird dabei von einer oszillierenden Vor- und Rückbewegung mit definierter Amplitude und Frequenz überlagert. Dadurch wird ein Spanbruch begünstigt und schwer abführbare sowie die Oberfläche beschädigende Langspäne vermieden.

2.2. Prozessüberwachung beim Bohren

In der Prozessüberwachung werden direkte Methoden von indirekten Methoden unterschieden [10]. Für eine direkte Messung des Werkzeugverschleißzustands oder der Werkstückqualität muss der laufende Prozess unterbrochen werden. Das Werkzeug oder Werkstück kann dann mittels eines externen Messgeräts vermessen werden. Methoden dieser Art weisen eine hohe Sicherheit und Genauigkeit bei der Bestimmung auf. Jedoch sind sie aufgrund der Prozessunterbrechung und zusätzlicher Nebenzeiten keine wirtschaftliche Lösung. Die indirekten Methoden nutzen hingegen im Prozess gemessene Sensordaten. Die Daten erlauben abhängig von ihrer Qualität einen indirekten Rückschluss auf Prozesszustände wie den Werkzeugverschleiß oder die Werkstückqualität. Auf Basis der gemessenen Prozessdaten kann sowohl eine modellbasierte als auch eine merkmalsbasierte Auswertung erfolgen [11]. Erstere nutzt die Daten zur Bestimmung von Modellparametern als Eingangsgröße in physikalische Modelle. Bei Letzterer werden die Sensorsignale in einzelne charakteristische Merkmale überführt. Im Rahmen einer Dimensionsreduktion und Relevanzanalyse können die für die Aufgabe relevantesten Merkmale identifiziert werden. Anschließend können sie mit den Werten eines Referenzzustands verglichen werden, um eine Veränderung im Prozess festzustellen und durch rechtzeitiges Eingreifen zu begrenzen. Dieses Vorgehen entspricht der klassischen Prozesskette einer indirekten Überwachung [10]. Für die Überwachung eines Zustands muss neben der geeigneten Auswahl der Sensorgrößen vor allem der Zusammenhang zwischen den gemessenen Sensorsignalen und der indirekt zu bestimmenden Größe auf Basis der Merkmale modellhaft beschrieben sein. Für diese Aufgabe kann die klassische Prozesskette durch Methoden des maschinellen Lernens erweitert werden.

Für das Training eines Vorhersagemodells werden die Prozessdaten in experimenteller Umgebung aufgenommen. Zusätzlich muss die vorherzusagende Zielgröße gemessen und den Prozessdaten zugeordnet werden. Daraus bilden sich für den Prozess des maschinellen Lernens ein Trainings-, Validierungs- und Testdatensatz für das Modelltraining. Das dann vorliegende Modell kann nach erfolgreicher Evaluation in den laufenden Prozess z. B. über ein Edge Device integriert werden. Untersuchungen zur Anwendung von Methoden des maschinellen Lernens finden sich in verschiedenen Bereichen der Produktionstechnik. In der Zerspangung und insbesondere bei Bohrprozessen bieten sie unter anderem Möglichkeiten für eine Überwachung des Werkzeugzustands und der Werkstückqualität [12]. Hierzu durchgeführte Untersuchungen und Anwendungen von Methoden des maschinellen Lernens lassen sich nach den verwendeten Sensorsignalen unterscheiden. Neben der Zerspankraft und dem Schnittmoment [13, 14], werden häufig Vibrationen [15], Körperschall [16], Prozesstemperaturen [17] und die Strom- und Leistungsaufnahme von Antrieben [18] als Datenbasis für eine Vorhersage herangezogen. Weiterhin wurden Untersuchungen zur Nutzung dieser Daten in Kombination mit Methoden des maschinellen Lernens sowohl für die Vorhersage des Werkzeugverschleißes als auch der Bohrungsqualität durchgeführt. Unter Nutzung der Daten konnten Support Vector Machines und Artificial Neural Networks [19] sowie Recurrent Neural Networks in Kombination mit einem Autoencoder [20] eine Vorhersage des Verschleißes ermöglichen. Vergleichbare Methoden konnten auch erfolgreich für die Vorhersage ausgewählter Größen zur Beschreibung der Bohrungsqualität angewendet werden. In [21] wurde auf der Basis von Vibrationsmessungen eines Artificial Neuronal Networks zur Vorhersage des Bohrungsdurchmessers und der Oberflächenrauheit der Bohrungswand beim Bohren in Titan/Aluminium Stacks trainiert. Die Grathöhe am Bohrungsaustritt konnte in [22] anhand ausgewählter Merkmale der Vorschubkraft überwacht werden. Die Delamination beim Bohren von CFK als weitere Qualitätskenngröße wurde in [23] in einem datenbasierten Überwachungskonzept berücksichtigt.

Die vorliegende Arbeit untersucht das Potential eines datenbasierten Überwachungskonzepts für semi-automatische Bohrprozesse, wozu bisher wenige Ergebnisse veröffentlicht wurden. Hierzu wurden der Einsatz und die Kombination von Vorbereitungsmethoden für Merkmale- und ML-Modelle untersucht und verglichen.

3. MATERIAL UND METHODEN

3.1. Bohrprüfstand und Messtechnik

Die Bohrversuche wurden mit der semi-automatischen Bohrvorschubeinheit SmartADU (Smart Advanced Drilling Unit) der Firma Lübbering durchgeführt. Die Maschine besitzt zwei Elektromotoren zur Ansteuerung der Vorschub- und Schnittbewegung des Bohrwerkzeugs. Zudem erlaubt die Maschine eine Einstellung der Peck-Feed Amplitude mit einem festen Frequenzverhältnis der Peck-Feed Bewegung des 1,5-fachen der Drehzahl. Die Einspannung der BVE erfolgt über eine mittels Druckluft aufspreizbare Spannzange (Concentric Collet) in eine dafür vorgesehene Schablone innerhalb der

Spannvorrichtung. Eine interne Sensorik erlaubt die Aufzeichnung des Spindel- und Vorschubmotorstroms I_{SP} und I_{VS} sowie der einwirkenden Beschleunigungen in drei Raumrichtungen a_x , a_y und a_z .

Die Durchführung der Untersuchungen und die Aufzeichnung von Prozessdaten erfolgte an einem Bohrprüfstand. Dieser ermöglicht die definierte Einspannung der BVE sowie die Positionierung und Einspannung des zu bohrenden Werkstoffs in Form eines Materialstreifens. Zudem ermöglicht der Bohrprüfstand die Unterbringung zusätzlicher externer Sensorik. Diese umfasst einen weiteren Beschleunigungssensor, sowie einen Laserpunktsensor zur Erfassung der Werkstückschwingung LS . Zusätzlich wird über ein Mikrofon der Schalldruckpegel L_p gemessen. Die gesamte Spannvorrichtung ist über eine Grundplatte auf das Maschinenbett einer Werkzeugmaschine gespannt. Anfallende Späne und CFK-Staub werden über eine Absaugung mit zwischengeschalteter Spanfalle abgesaugt. Das BILD 1 zeigt die Anordnung der einzelnen Komponenten. Die TAB 1. listet die Bezeichnungen der einzelnen Sensorsysteme auf.

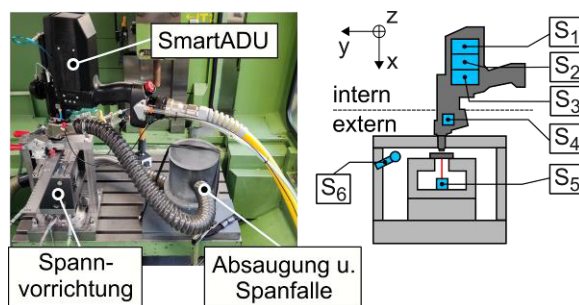


BILD 1. Bohrprüfstand und Messtechnik

Interne Sensorik			
Nr.	Bezeichnung	Messgrößen	Abtastrate
S ₁	Beschleunigung	a_x, a_y, a_z	100 Hz
S ₂	Vorschubstrom	I_{VS}	100 Hz
S ₃	Spindelstrom	I_{SP}	100 Hz
Externe Sensorik			
S ₄	Beschleunigung	a_x, a_y, a_z	5120 Hz
S ₅	Werkstückschwingung	LS	5120 Hz
S ₆	Schalldruckpegel	L_p	5120 Hz

TAB 1. Eingesetzte Sensorsysteme

In zwei Versuchsreihen wurde das Verschleißverhalten an zwei typischen Leichtbauwerkstoffen untersucht. Die einzelnen Konfigurationen (MMS: Minimalmengenschmierung, A_{PF} : Peck-Feed-Amplitude) und Schnittparameter der Versuchsreihen kann der nachstehenden TAB. 2 entnommen werden.

Nr	Werkstoff	f [mm]	n [min ⁻¹]	MMS	A_{PF}
V1	Ti6Al4V	0,05	750	100 %	62,5 μ m
V2	CFK	0,06	6000	0 %	125 μ m

TAB 2. Schnittparameter und Maschinenkonfiguration

Bei dem CFK handelte sich um Hexply M21E-IMA-31-194 Prepreg mit einer Glaslage auf der Bohrertrittsseite und einem Matrixvolumenanteil von 31 %.

Für jede der Versuchsreihen wurden 225 Bohrungen mit jeweils einem Werkzeug vom gleichen Typ durchgeführt. Dabei handelt es sich um einen unbeschichteten

Vollhartmetall-Spiralbohrer mit einem Durchmesser von $D = 6,36$ mm, einer Zähnezahl von $z = 2$, einen Spitzenwinkel von $\sigma = 135^\circ$, einen Seitenfreiwinkel von $\alpha_f = 16^\circ$ und einen Seitenspanwinkel von $\gamma_f = 15^\circ$.

3.2. Vermessung von Qualität und Verschleiß

Für eine Vorhersage des aktuellen Qualitäts- und Verschleißzustands beim Bohren müssen zusätzlich zur Aufnahme der Prozessdaten ausgewählte Qualitäts- und Verschleißkenngrößen am Werkstück und am Bohrwerkzeug gemessen werden. Sie dienen beim anschließenden Modelltraining als Antwortgröße innerhalb der Designmatrix. Bei der Ermittlung der Kenngrößen kamen verschiedene Messverfahren zum Einsatz.

Die Ermittlung der Bohrungsqualität erfolgte anhand von zwei Qualitätskenngrößen. Die Austrittsgrathöhe wurde für die Bohrungen in TiAl6V4 mit einem Grathöhenmessgerät (*Mitutoyo 2046F*) ermittelt. Für die Bohrungen in CFK wurde der Faktor F_D zur Beschreibung der Delamination ermittelt. Der Delaminationsfaktor F_D ist die von Delamination eingeschlossene Fehlerfläche A_{err} bezogen auf die Nennfläche A_n der Bohrung mit Nenndurchmesser $D = 6,36$ mm, die unter dem Mikroskop ermittelt wurde.

Im Gegensatz zur Vermessung der Bohrungsqualität erfolgte die Vermessung des Verschleißzustands nicht nach jeder gefertigten Bohrung. Stattdessen wurde der Verschleißzustand anhand ausgewählter Verschleißgrößen nach den ersten drei, sechs und zehn Bohrungen gemessen. Weitere Messungen erfolgten alle 15 Bohrungen. Ab der 120. Bohrung wurde alle zehn Bohrungen der Verschleißzustand erfasst. Dokumentiert wurden sowohl Aufnahmen der Freiflächen, Spanflächen und Schneidenecken des Bohrwerkzeugs unter einer Stereolupe (*Olympus SZX10*) als auch 3D-Aufnahmen der Schneidkeile (*Alicona InfiniteFocus G4*). Aus den Aufnahmen der Stereolupe wurden die Verschleißmarkenbreite VB_{max} und die Fläche von Ausbrüchen auf der Freifläche A_{Bruch} ermittelt. Aus den 3D-Aufnahmen wurde der Hauptschneidenradius r_p ermittelt.

4. DATENANALYSE UND MODELLTRAINING

4.1. Datenaufbereitung

Die Datenverarbeitung und das Modelltraining wurden in Matlab R2021b durchgeführt. Das Modelltraining auf Basis der aufgezeichneten Prozessdaten erfordert die Umsetzung verschiedener Schritte zur Datenverarbeitung und -analyse. Alle gemessenen Signale wurden auf die drei Phasen eines Bohrprozesses aufgeteilt und im weiteren Verlauf als individuelle Signalverläufe für die Eintrittsphase, den Vollschnitt und die Austrittsphase des Bohrwerkzeugs behandelt. BILD 2 zeigt am Beispiel des gemessenen Vorschubstroms einer Bohrung die Aufteilung eines Signals. Eine Aufteilung der Signale erfolgte anhand des Gradienten. Ansteigende Signalanteile werden dem Eintritt und absteigende Anteile dem Austritt zugeordnet. Der Vollschnitt ist durch einen horizontalen Signalverlauf gekennzeichnet.




BILD 2. Aufteilung am Beispiel des Vorschubstroms I_{vs}

Die Aufteilung der Signale ermöglicht eine separate Berechnung von Merkmalen für die einzelnen Abschnitte.

4.2. Merkmalsberechnung und Designmatrix

An die Datenaufbereitung schließt sich die Berechnung der Merkmale und Zusammensetzung der Designmatrix für das Modelltraining an. Dabei handelt es sich im Wesentlichen um die Berechnung von grundlegenden statistischen Kennwerten. Alle Merkmale werden für jede Phase des Bohrprozesses und für das gesamte Signal berechnet. Zusätzlich zum Zeitbereich werden auch die Fouriertransformation in den Frequenzbereich sowie die Wavelettransformation (Debauchie-4 Wavelet, Transformationslevel: 6) in den Zeit-Frequenzbereich bei der Merkmalsberechnung berücksichtigt. Zusätzlich wurden weitere für den jeweiligen Signaltyp charakteristische Merkmale berechnet. Dies umfasst unter anderem Hüllkurven und die davon eingeschlossenen Flächen der Signale im Zeitbereich sowie spektrale Kennwerte aus dem Zeit- und Frequenzbereich des gemessenen Schalldruckpegels L_p . Dabei handelt es sich um Merkmale, die typischerweise bei der Verarbeitung von Audiosignalen zum Einsatz kommen. Neben der Berechnung der Merkmale aus den gemessenen Prozessdaten wurde die Historie des Bohrwerkzeugs in Form der Anzahl bereits gefertigter Bohrungen berücksichtigt.

Ein einzelnes berechnetes Merkmal besitzt folglich immer eine Zugehörigkeit zu einem Signalbereich (vgl. BILD 2) und einer Prozessgröße aus der es berechnet wurde (vgl. TAB. 1). Dies erlaubt die Beurteilung der Prozessgrößen und ihrer Signalbereiche hinsichtlich der Merkmalsrelevanz im weiteren Verlauf. Die Berechnung der Merkmale erfolgte für jede gefertigte Bohrung (Beobachtung). Das Ergebnis der Merkmalsberechnung bildet einen Baustein für die Designmatrix der jeweiligen Versuchsreihe. Sie stellt den gesamten Datensatz dar, der für das Modelltraining und die Evaluation verwendet wird. Zur Vervollständigung der Designmatrix fehlt neben den Merkmalen jeder Beobachtung die Zuordnung einer der Antwortgrößen. Als Antwortgröße stehen sowohl die Qualitätskenngrößen der gefertigten Bohrung als auch die Verschleißkenngrößen des Bohrwerkzeugs aus den Vermessungen zur Verfügung, die separat in mehreren Modelltrainings berücksichtigt werden.

Für das Training von Regressionsmodellen für die Verschleißvorhersage wurden die gemessenen Verschleißkenngrößen unter Einsatz von Interpolationspolynomen auf die übrigen Beobachtungen ausgeweitet, da nicht für jede Bohrung eine Verschleißmessung durchgeführt wurde. Im Fall der

Qualitätskenngrößen standen immer so viele Messungen wie Bohrungen zur Verfügung. Im Fall einer Klassifikation werden die Kenngrößen über die Angabe eines Schwellwerts in die zwei Klassen oberhalb (negativ) und unterhalb (positiv) des Schwellwerts überführt. Der Schwellwert wurde für jede Kenngröße individuell festgelegt, sodass eine gleichmäßige Klassenverteilung im Datensatz erreicht wurde. Die Kombination aus berechneten Merkmalen und einer Antwortgröße für eine Klassifikation oder Regression bildet die grundlegende Datenbasis für die Durchführung eines Modelltrainings.

4.3. Dimensionsreduktion

Unter Anwendung verschiedener Dimensionsreduktionsmethoden wurden Merkmale mit hoher Relevanz innerhalb aller vorliegenden Merkmale identifiziert, wodurch die Gesamtanzahl an Merkmalen für das Modelltraining reduziert werden konnte. Aus einer Designmatrix ergeben sich unter Berücksichtigung verschiedener Dimensionsreduktionsmethoden neue reduzierte Designmatrizen, die eine Untersuchung des Einflusses der verschiedenen Methoden auf die Modellperformance ermöglichen. Die folgende TAB. 3 zeigt eine Übersicht der verwendeten Dimensionsreduktionsmethoden und ihre Anwendung in der Regression (R.) und Klassifikation (K.).

Methode	Abk.	R.	K.
Classical Multidimensional Scaling	CMS	X	X
F-Test	FT	X	
Min. Redundancy Max. Relevance	MRMR		X
Nonnegative Matrix Factorization	NMF	X	X
Principal Component Analysis	PCA	X	X
Keine Dimensionsreduktion	NoRed.	X	X

TAB 3. Dimensionsreduktionsmethoden

Die Ergebnisse des F-Tests werden darüber hinaus für die Untersuchung der Merkmalsrelevanz herangezogen. Beim F-Test handelt es sich um ein statistisches Prüfverfahren. Die Ermittlung des F-Werts erlaubt eine Aussage darüber, ob ein signifikanter Unterschied in der Varianz zweier Stichproben vorliegt. Darüber hinaus bestimmt der F-Wert den sogenannten p-Wert. Er beschreibt die Wahrscheinlichkeit, dass ein beobachteter Unterschied in den Verteilungen nur zufällig auftritt. Der Logarithmus des p-Werts wurde als Relevanzwert R zur Beschreibung der Wichtigkeit eines einzelnen Merkmals herangezogen.

4.4. Trainingsprozess

Das Training von Klassifikations- und Regressionsmodellen erfolgte für jede Versuchsreihe und für alle Kombinationen aus Antwortgröße, Dimensionsreduktionsmethode sowie Modell-Algorithmus. Diese Vorgehensweise erlaubt im Rahmen der sich anschließenden Modellevaluation die Herausstellung der besten fünf Kombinationen und die Bestimmung von Einflüssen der ausgewählten Methodik und Antwortgrößen.

Für das Training wurde die jeweilige Designmatrix zufällig nach dem Prinzip der Hold-Out-Validierung in einen Trainings- und Testdatensatz aufgeteilt. Jedes Training wurde in Matlab mit dem Einsatz einer automatischen Hyperparameteroptimierung vorhandener Modellparame-

ter unter Anwendung eines Bayes'schen Optimierungsalgorithmus durchgeführt.

5. VERLAUF VON QUALITÄT UND VERSCHLEIß

5.1. Verschleißkenngrößen

Im Folgenden werden die Verläufe der in den Untersuchungen ermittelten Qualitäts- und Verschleißkenngrößen über die 225 gebohrten Nietbohrungen vorgestellt. Dazu wird die Interpolation der Verschleißkenngrößen und die Klassenaufteilung an den dargestellten Verläufen visualisiert. Das BILD 3 zeigt die Entwicklung der Verschleißmarkenbreite über die Anzahl der gefertigten Bohrungen. Dabei zeichnet sich ein typischer Verschleißverlauf in den Versuchsreihen für das Bohren in TiAl6V4 und CFK ab. Beim Bohren in CFK werden höhere Verschleißmarkenbreiten VB_{max} erreicht. Dies ist auf die stark abrasive Wirkung der CFK-Fasern auf das Werkzeug zurückzuführen. Die auf den Einzelmessungen basierende Interpolation des Verlaufs stellen eine gute Approximation für dazwischenliegende Beobachtungen dar. Eine horizontale Linie kennzeichnet den Schwellwert zur Aufteilung der gemessenen und interpolierten Werte auf zwei Klassen. Die Grenze teilt einen Datensatz in zwei Hälften, um den Einfluss einer ungleichen Klassenverteilung auf das Modelltraining zu vermeiden. Daraus ergeben sich die beiden Klassen oberhalb und unterhalb des Schwellwerts, die zwei verschiedene Verschleißzustände des Bohrwerkzeugs repräsentieren.

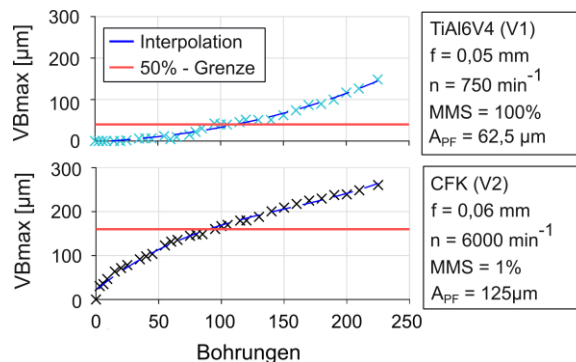


BILD 3. Verlauf der Verschleißmarkenbreiten VB_{max}

Durch die Vermessung der Verschleißmarkenbreite VB_{max} wird vor allem das beim Bohren von Ti6Al4V auftretende Verschleißbild des Bohrwerkzeugs nicht vollständig erfasst. Dieses ist neben einer allgemeinen Abstumpfung des Schneidkeils vor allem durch das Auftreten von Ausbrüchen über die gesamte Länge beider Schneiden gekennzeichnet. Die Ausbrüche erschweren die Ermittlung des Schneidkantenradius für das Bohrwerkzeug in Versuchsreihe V1. Daher wurde zusätzlich die Ausbruchfläche A_{Bruch} auf der Freifläche in BILD 4 ermittelt. Darüber hinaus wird der Zusammenhang zwischen dem Schneidkantenradius r_β beim Bohren in CFK in BILD 4 mit der Verschleißmarkenbreite VB_{max} in BILD 3 deutlich. Beide weisen qualitativ ähnliche Verläufe auf.




BILD 4. Ausbruchfläche A_{Bruch} und Radius r_β

5.2. Qualitätskenngrößen

In vergleichbarer Weise wurde mit den Kenngrößen zur Beschreibung der Bohrungsqualität verfahren. Das BILD 5 zeigt dies am Beispiel der beiden Qualitätskenngrößen Austrittsgrat beim Bohren in TiAl6V4 und dem Delaminationsfaktor F_D zur Beschreibung der Delamination am Bohrungsausritt von CFK. Für jede Bohrung liegt eine Messung vor und eine gleichmäßige Klassenaufteilung erfolgte gemäß des ausgewählten Schwellwerts.

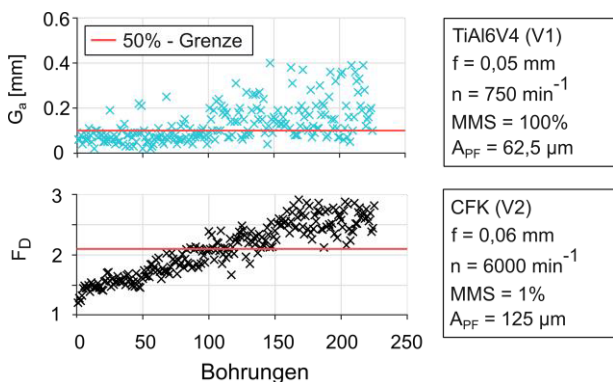


BILD 5. Austrittsgrat G_a und Delamination F_D

6. ANALYSE DER MERKMALSRELEVANZ

Zur Untersuchung der Relevanz einzelner Merkmale in der gesamten Designmatrix können Methoden zur Dimensionsreduktion herangezogen werden. Ausgewählte Methoden berücksichtigen neben den Merkmalen auch die Antwortgröße. Das Ergebnis sind Werte zur Beschreibung der relativen Wichtigkeit eines Merkmals innerhalb der Designmatrix. Auf Basis der Dimensionsreduktionsmethode F-Test für eine sequentielle Merkmalsselektion wurden die Merkmale mit der höchsten Relevanz gegenüber den übrigen Merkmalen bestimmt. Aus den genaueren Eigenschaften eines Merkmals können Rückschlüsse auf die Eignung der verwendeten Sensoren, Signalbereiche und Transformationen für eine Vorhersage einer ausgewählten Antwortgröße geschlossen werden.

6.1. F-Test (Verschleißkenngrößen)

Die TAB. 4 und TAB. 5 zeigen den Relevanzwert R der jeweils fünf relevantesten Merkmale, die für jede

Antwortgröße zur Beschreibung des Werkzeugverschleißes in V1 und V2 aus dem F-Test hervorgegangen sind. Für alle Antwortgrößen stellt die Anzahl gefertigter Bohrungen das wichtigste Merkmal dar. Alle darauffolgenden Merkmale weisen für die Antwortgrößen verschiedene Kombinationen aus Signalbereich, Sensor, Kennwert und Transformation (TF) auf. Eine Gemeinsamkeit der Antwortgrößen untereinander besteht in der Einstufung von Merkmalen auf Basis des Vorschubmotorstroms I_{VS} .

Verschleißmarkenbreite VBmax, TiAl6V4 (V1)					
Nr	Bereich	Sensor	Kennwert	TF	R
1	-	-	Bohrungen	ZB	21
2	Austritt	I_{VS}	rmse	WT	20
3	Vollschnitt	I_{VS}	mean	WT	16
4	Gesamt	L_p	iqr	WT	15
5	Vollschnitt	a_z (ex.)	iqr	ZB	15
Verschleißmarkenbreite VBmax, CFK (V2)					
1	-	-	Bohrungen	ZB	24
2	Austritt	I_{VS}	max	ZB	24
3	Gesamt	I_{VS}	std	ZB	24
4	Gesamt	I_{VS}	var	ZB	24
5	Gesamt	I_{VS}	std	WT	24

TAB 4. F-Test für die Verschleißmarkenbreite (std: Standardabweichung, mean: Mittelwert, iqr: Interquartilsabstand, var: Varianz, rmse: root mean squared error)

Ausbruchfläche A_{Bruch} , TiAl6V4 (V1)					
Nr	Bereich	Sensor	Kennwert	TF	R
1	-	-	Bohrungen	ZB	250
2	Gesamt	I_{VS}	range	ZB	170
3	Eintritt	I_{VS}	iqr	ZB	167
4	Eintritt	I_{VS}	range	WT	166
5	Eintritt	I_{VS}	std	WT	166
Schneidkantenradius r_β , CFK (V2)					
1	-	-	Bohrungen	ZB	369
2	Gesamt	I_{VS}	mad	ZB	326
3	Gesamt	I_{VS}	range	WT	321
4	Gesamt	I_{VS}	std	WT	319
5	Gesamt	I_{VS}	var	WT	319

TAB 5. F-Test für Ausbruchfläche und Radius (range: maximale Wertedifferenz, mad: mean average deviation, std: Standardabweichung, var: Varianz, iqr: Interquartilsabstand)

Die Signalbereiche treten bis auf den Fall der Verschleißmarkenbreite VBmax beim Bohren von Titan vergleichsweise einheitlich auf. Für jede Antwortgröße lässt sich ein dominanter Signalbereich identifizieren. Dabei sind vor allem der Gesamtbereich als auch der Eintrittsbereich stärker gegenüber dem Austrittsbereich vertreten. Hinsichtlich der Signaltransformationen treten sowohl der Zeitbereich (ZB) als auch der Zeit-Frequenzbereich der Wavelet Transformation (WT) in Kombination mit relevanten Merkmalen auf

6.2. F-Test (Qualitätskenngrößen)

Die TAB. 6 zeigt die Relevanzwerte R des F-Tests der Untersuchung der Merkmalsrelevanz für die Qualitätskenngrößen Austrittsgrathöhe G_a und Delaminationsfaktor F_D als Antwortgröße.

Austrittsgrathöhe G_a , TiAl6V4 (V1)					
Nr	Bereich	Sensor	Kennwert	TF	R
1	Austritt	I_{VS}	rmse	ZB	30
2	Austritt	I_{VS}	rmse	WT	26
3	Austritt	I_{VS}	mean	ZB	26
4	Austritt	I_{VS}	mean	WT	26
5	Austritt	I_{VS}	max	ZB	26
Delamination F_D , CFK (V2)					
1	-	-	Bohrungen	ZB	166
2	Gesamt	I_{VS}	std	ZB	159
3	Gesamt	I_{VS}	var	ZB	159
4	Gesamt	I_{VS}	std	WT	159
5	Gesamt	I_{VS}	var	WT	159

TAB 6. F-Test für Qualitätskenngrößen

Eine Gemeinsamkeit mit den Ergebnissen der Verschleißkenngrößen ist das Auftreten des Vorschubmotorstroms I_{VS} . Darüber hinaus unterscheiden sich die berechneten Kennwerte jedoch in den für die Merkmalsberechnung berücksichtigten Signalbereich. Während relevante Merkmale für den Austrittsgrat aus dem Austrittsbereich des Signals stammen, basieren die relevanten Merkmale der Delamination auf den Gesamtbereich des Signals.

7. EVALUATION DER VORHERSAGEMODELLE

Die Evaluation der trainierten ML-Modelle erfolgte für die Klassifikationsmodelle anhand der Accuracy, dem Recall und der Precision. Dabei handelt es sich um Größen zur Beschreibung Klassifikationsgüte eines Klassifikationsmodells, die die Zuordnung einer Beobachtung in eine der vorhandenen Klassen berücksichtigen. Zur Beurteilung der Vorhersagegüte der Regressionsmodelle wurde der RMSE (root mean squared error) herangezogen. Für die Ermittlung der besten fünf Kombinationen aus Modellalgorithmus und Dimensionsreduktionsmethode für jede Antwortgröße wurde ein Score zwischen 0 % und 100 % ermittelt. Der Score berücksichtigt neben den Größen zur Bewertung der Klassifikation (Accuracy, Recall und Precision) auch die Vorhersagezeit eines Modells bei der Auswertung des Testdatensatzes. Hierbei repräsentiert 100 % die beste Modellperformance in Kombination mit der kleinsten Vorhersagezeit.

7.1. Klassifikation der Qualitätskenngrößen

Das BILD 6 zeigt die Bewertung der Modelle für die Klassifikation des Austrittsgrats. Das beste Modell ist eine Discriminant Analysis (DA) und erreicht eine Accuracy von 79,1 %. Die anderen vier Modelle erreichen eine vergleichbare Accuracy von mindestens 76,1 %. Dabei handelt es sich um eine lineare Regression (LR) und Support Vector Machine (SVM). Am schlechtesten schnitt das Naives Bayes Modell (NB) ab.




BILD 6. Bewertung der Klassifikation des Austrittsgrats

Für die Klassifikation der Delamination in BILD 7 können insgesamt bessere Vorhersagegüten durch die Klassifikationsmodelle erreicht werden. Beim besten Modell handelt es sich um eine Support Vector Machine, die eine Accuracy von 91,1 % erreicht. Ähnliche Ergebnisse konnten von einem Entscheidungsbaummodell (Tree) und neuronalen Netzwerken (ANN) erreicht werden. Die niedrigste Vorhersagegenauigkeit wurde von einem Boosted Tree (BT) Algorithmus mit einer Accuracy von 70 % erreicht.




BILD 7. Bewertung der Klassifikation der Delamination

7.2. Klassifikation der Verschleißkenngrößen

Im Vergleich zur Klassifikation der Qualitätskenngrößen weisen die Modelle zur Klassifikation des Verschleißes für alle Kenngrößen bessere Vorhersagegüten auf. Dies ist vor allem auf die vergleichsweise geringe Varianz der Messdaten und Interpolationsergebnisse der Verschleißkenngrößen zurückzuführen, die aus BILD 4 und BILD 5 qualitativ ersichtlich ist. BILD 8 bis BILD 11 zeigen die Ergebnisse der Evaluierung für die Klassifikation des Verschleißes. Für die Verschleißmarkenbreiten beider Versuchsreihen VB_{max} sowie für die Ausbruchfläche A_{Bruch} der Versuchsreihe V1 und den Schneidkantenradius r_β der Versuchsreihe V2 bilden Entscheidungsbaummodelle in Kombination mit verschiedenen Dimensionsreduktionsmethoden die Modelle mit hohen Vorhersagegüten.




BILD 8. Bewertung der Klassifikation von VB_{max} (V1)




BILD 9. Bewertung der Klassifikation von VB_{max} (V2)




BILD 10. Bewertung der Klassifikation von A_{Bruch} (V1)




BILD 11. Bewertung der Klassifikation von r_β (V2)

Insgesamt lassen sich für alle Verschleißkenngrößen Vorhersagemodelle mit guten Vorhersagegüten trainieren. Die sehr hohen Vorhersagegüten werden durch Werte für die Accuracy, Precision und den Recall von nahe 100 % deutlich.

7.3. Regression der Qualitätskenngrößen

Da es sich bei dem RMSE um einen Fehlerwert in der Einheit der jeweiligen Antwortgröße handelt, ist ein direkter Vergleich zwischen den RMSE-Werten der jeweiligen Antwortgrößen nicht möglich. Zur Beurteilung muss der RMSE immer den tatsächlichen Werten der Vorhersage gegenübergestellt werden. Im Fall der Austrittsgrathöhe in BILD 12 weist die Lineare Regression als bestes Modell einen RMSE von 0,08 mm auf.




BILD 12. Bewertung der Regression von G_a

Damit liegt er deutlich über den kleinsten gemessenen Grathöhen von 0,03 mm. Im Vergleich zu dem höchsten gemessenen Austrittsgrat von 0,5 mm fällt der Fehler kleiner aus. Die Ergebnisse für die Regression der Delamination F_D in BILD 13 weisen für die besten Modelle gute Vorhersagegüten im Vergleich zu den für den Delaminationsfaktor ermittelten Werte. Sowohl für den Austrittsgrat als auch für die Delamination treten die Lineare Lasso Regression (LLR), Lineare Regression (LR) sowie die Gaussian Process Regression (GPR) als ML-Modelle mit den besten Ergebnissen auf. Der Großteil der Modelle tritt in Kombination mit dem F-Test als Dimensionsreduktionsmethode auf.




BILD 13. Bewertung der Regression von F_D

7.4. Regression der Verschleißkenngrößen

Die besten Regressionsmodelle zur Vorhersage einer Verschleißkenngröße weisen unabhängig der durchgeführten Versuchsreihe gute Vorhersagegüten auf. Beim Training der Regressionsmodelle traten deutliche Unterschiede in den Trainings- und Vorhersagezeiten der verschiedenen Modelle auf. Dies sorgt bei der Ermittlung des Scores für eine Reihenfolge der Platzierung, die nicht in allen Fällen den kleinsten Wert für den RMSE folgt. Dennoch ist der kleinste erzielte RMSE immer innerhalb der ersten fünf Platzierungen vertreten.

Die Ergebnisse in BILD 14 bis BILD 17 erzielen mit dem jeweils besten Modell hinsichtlich ihres RMSE gute Regressionen der Antwortgrößen im Vergleich zu den gemessenen Werten.




BILD 14. Bewertung der Regression von VB_{max} (V1)




BILD 15. Bewertung der Regression von VB_{max} (V2)

Für die Vorhersage der Verschleißmarkenbreite VB_{max} wird im Fall der Versuchsreihe V1 durch eine Kombination aus einem Entscheidungsbaum und dem F-Test der kleinste RMSE erreicht. Im Fall der Versuchsreihe V2 handelt es sich um eine Gaussian Process Regression. Für die Ausbruchfläche A_{Bruch} der Versuchsreihe V1 wird das beste Ergebnisse mittels Linear Lasso Regression (LLR) und für den Schneidkantenradius der Versuchsreihe V2 mittels neuronalen Netzwerks erreicht. Bei der Regression treten die Modelle überwiegend in Kombination mit dem F-Test als Dimensionsreduktionsmethode auf.




BILD 16. Bewertung der Regression von A_{Bruch} (V1)




BILD 17. Bewertung der Klassifikation von r_β (V2)

8. ZUSAMMENFASSUNG

In dieser Arbeit wurde eine Routine zur Auswertung gemessener Prozessgrößen beim Bohren von TiAl6V4 und CFK in Matlab entwickelt. Die Auswertung diente dem Training von Vorhersagemodellen im Rahmen des Maschinellen Lernens zur Bestimmung des aktuellen Verschleißzustands des Bohrwerkzeugs und der Ausprägung von Qualitätskenngrößen an der gefertigten Bohrung. Eine Auswertung erfolgte auf der Basis von in Experimenten aufgezeichneten Prozessdaten beim Bohren von insgesamt 450 Bohrungen. Die Ergebnisse der Arbeit tragen zu einer verbesserten Ausnutzung von Bohrwerkzeugen in semi-automatischen Bohrvorschubeinheiten bei. Es wird gezeigt, dass vor allem die interne Sensorik dazu genutzt werden kann, um in einer laufenden Produktion genauere Kenntnisse über den Zustand der Bohrwerkzeuge und Werkstücke zu erhalten. Hierdurch kann auf Basis von ML-Modellen, die auf einen Prozess abgestimmt sind, eine effizientere Ausnutzung der Werkzeuge erfolgen und Fehler im Prozess frühzeitig erkannt werden.

Die Ergebnisse dieser Arbeit teilen sich auf zwei Hauptuntersuchungen auf:

- 1) Untersuchung der Merkmalsrelevanz und deren Bezug zu gemessenen Prozessgrößen und Signalbereichen:
 - Die Berechnung eines Relevanzwertes durch den F-Test hat gezeigt, dass die Relevanz eines Merkmals eine Abhängigkeit zum betrachteten Signalbereich (Gesamt, Eintritt, Austritt, Vollschnitt) aufzeigt.
 - Die Wavelettransformation hat sich als wichtige Transformation bei der Berechnung von Merkmalen herausgestellt.
 - Die Berücksichtigung verschiedener Qualitäts- und Verschleißkenngrößen als Antwortgröße führt zu Unterschieden in den wichtigsten identifizierten Merkmalen.

- Der Vorschubmotorstrom konnte als wichtige Datenbasis für die Berechnung von Merkmalen identifiziert werden.

- 2) Ermittlung der besten Kombinationen aus Dimensionsreduktionsmethode und ML-Modell für Regression und Klassifikation von Antwortgrößen:

- Bei der Klassifikation konnten die besten Ergebnisse für die Vorhersage des Delaminationsfaktors F_D unter Anwendung einer Support Vector Machine und Classical Multidimensional Scaling erzielt werden.

- Alle Verschleißkenngrößen konnten aufgrund ihrer monoton ansteigenden Verläufe unter Anwendung von Klassifikationsbäumen vorhergesagt werden.

- In der Regression der Qualitätskenngrößen konnte ebenfalls für den Delaminationsfaktor F_D das beste Modell als Kombination aus Linear Ridge Regression und dem F-Test ermittelt werden.

- Alle Verschleißkenngrößen ließen sich mit kleinen Fehlerwerten in der Regression vorhersagen.

- [1] Airbus Group: Qualität – Besser bohren. One – Airbus News for Airbus People, (2015)
- [2] Deutsches Zentrum für Luft- und Raumfahrt: Corona und dann? Neue DLR-Prognose für den Luftverkehr bis 2040, (2021), URL: <https://www.dlr.de/blogs/alle-blogs/corona-und-dann-neuedlr-prognose-fuer-den-luftverkehr-bis-2040.aspx> (besucht am 10.01.2022)
- [3] Boeing: Commercial Market Outlook 2021 – 2040, (2021), URL: <https://www.boeing.com/commercial/market/commercial-market-outlook/> (besucht am 10.10.2021)
- [4] Schüpach, H.: Prozessregulation in rechnerunterstützten Fertigungssystemen. Mensch, Technik, Organisation (1994) Bd. 4, Verlag der Fachvereine, Teubner
- [5] Stöver, E.: Untersuchungen zum Bohren des Faser-Metall-Laminates Glare sowie von Glare-Schichtverbunden. (2007), Cuvillier Verlag, Göttingen
- [6] Hintze, W.; Lödding, H.; Friedewald, A.; Mehnen, J.; Romanenko, D.; Sikorra, J. N.: Digitalisierte Bohrtechnologie für die Strukturmontage. Innovation Report (2019), S.46 – 47
- [7] Ammon, C.: Modern Aircraft Production: Of Rivets and Transport Robots. German Aerospace Industries Association (2019), URL: https://www.bdli.de/en/innovation_of_the_week/moder-n-aircraft-production-rivets-and-transport-robots (besucht am 10.10.2021)
- [8] Hintze, W.; Lödding, H.; Friedewald, A.; Mehnen, J.; Romanenko, D.; Möller, C.; Brillinger, C.; Sikorra, J.

- N.: Digital Assistance Systems for Smart Drilling Units in Aircraft Structural Assembly. Proceedings of the 7th International Workshop on Aircraft System Technologies (2019), S. 255 – 266
- [9] Köttner, L.; Mehnen, J.; Romanenko, D.; Bender, S.; Hintze, W.: Process Monitoring Using Machine Learning for Semi-Automatic Drilling of Rivet Holes in the Aerospace Industry. Production at the leading edge of technology (2021), S. 497 – 507
- [10] Teti, R.; Jemielniak, K.; O'Donnell, G.; Dornfeld, D.: Advanced monitoring of machining operations. CIRP Annals (2010), S. 717 – 739
- [11] Dolinsek, S.: Cutting Tool Wear Monitoring. Encyclopedia of tribology. Springer US (2013), S. 677 – 687
- [12] Mayr, A.; Kisskalt, D.; Meiners, M.; Lutz, B.; Schäfer, F.; Seidel, R.; Selmaier, A.; Fuchs, J.; Metzner, M.; Blank, A.; Franke, J.; Machine Learning in Production – Potentials, Challenges and Exemplary Applications. Procedia CIRP (2019), S. 49 – 54
- [13] Ashrafi, S.; Davoudinejad, A.; Barzani, M. M.; Salehi, P.: Investigation into Effect of Tool Wear on Drilling Force and Surface Finish While Drilling Aluminum 2024. Advanced Materials Research (2012), S. 387 – 392
- [14] Eynian, M.; Das, K.; Wretland, A.: Effect of Tool Wear on Quality in Drilling Titanium Alloy Ti6Al4V, Part I: Cutting Forces, Burr Formation, Surface Quality and Defects. High Speed Maching (2017), S. 1 – 10
- [15] Kilundu, B.; Dehombreux, P.; Chiementin, X.: Tool Wear Monitoring by Machine Learning and Singular Spectrum Analysis. Mechanical Systems and Signal Processing (2011), S. 400 – 415
- [16] Jantunen, E.: A Summary of Methods Applied to Tool Condition Monitoring in Drilling. International Journal of Machine Tools and Manufacture (2002), S. 997 – 1010
- [17] Angelone, R.; Caggiano, A.; Importa, I.; Nele, L.; Teti, R.: Temperature Measurements for the Tool Wear and Hole Quality Assessment During Drilling of CFRP/CFRP Stacks. Procedia CIRP (2018), S. 416 – 421
- [18] Lee, J. M.; Choi, D. K.; Kim, J.; Chu, C. N.: Real-Time Tool Breakage Monitoring for NC Milling Process. CIRP Annals (1995), S. 59 – 62
- [19] Alajmi, M. S.; Almesahl, A. M.: Predicting the Tool Wear of a Drilling Process Using Novel Machine Learning XGBoost-SDA. Materials (2020)
- [20] Caggiano, A.; Mattera, G.; Nele, L.: Smart Tool Wear Monitoring of CFRP/CFRP Stack Drilling Using Autoencoders and Memory-Based Neural Networks. (2023) Applied Science, MDPI AG
- [21] Cruz, C. E. D.; de Aguiar, P. R.; Machado, Á. R.; Bianchi, E. C.; Contrucci, J. G.; Neto, F. C.: Monitoring in Precision Metal Drilling Process Using Multi-Sensors and Neural Network. The International Journal of Advanced Manufacturing Technology (2013), S. 151 – 158
- [22] Rimpault, X.; Chatelain, J.-F.; Klemberg-Sapieha, J. E.; Balazinski, M.: Burr Height Monitoring While Drilling CFRP/Titanium/Aluminium Stacks. Mechanics and Industry (2017), S. 114
- [23] Shaban, Y.; Yacout, S.; Balazinski, M.; Meshreki, M.; Attia, H.: Diagnosis of Machining Outcomes Based on Machine Learning with Logical Analysis of Data. International Conference on Industrial Engineering and Operations Management (2015), IEEE, S. 1 – 8