

# Generisches Framework für akustische Methoden zur Überwachung industrieller Fertigungsprozesse

Thomas SCHLECH<sup>1</sup>, Florian F. LINSCHIED<sup>1</sup>, Marcel ACHZET<sup>1</sup>,  
Christina BAUMEISTER<sup>1</sup>, Quy R. LUONG<sup>1</sup>, Bastian BRÜCK<sup>1</sup>, Markus G. R. SAUSE<sup>1</sup>  
<sup>1</sup> Universität Augsburg, Institut für Materials Resource Management, Mechanical  
Engineering, D-86159 Augsburg

Kontakt E-Mail: thomas.schlech@mrm.uni-augsburg.de

**Kurzfassung.** Digitale Technologien in der Produktion zeigen gerade im Fall komplexer Fertigungsprozesse großes Potential und gewinnen daher zunehmend an Bedeutung. Um die sich daraus ergebenden Möglichkeiten nutzen zu können, ist die Datengewinnung durch sensorische Überwachung der jeweiligen Prozesse unerlässlich. Neben der reinen Aufzeichnung stellt besonders die automatisierte Weiterverarbeitung der Daten einen wichtigen Schritt für den erfolgreichen Einsatz von Prozessüberwachungssystemen in einem industriellen Umfeld dar. Im Rahmen der vorgestellten Arbeit werden Sensorsysteme zur Überwachung verschiedener industrieller Prozesse eingesetzt. Der Schwerpunkt liegt dabei vor allem auf akustischen Methoden, wie z.B. der Körperschall- und Schallemissionsanalyse sowie Methoden der aktiven Ultraschallüberwachung. Der Einsatz der Messsysteme wird dabei für verschiedene Fertigungsprozesse aus den Bereichen Zerspanung, Kunststoffverarbeitung und Fügetechnologien betrachtet. Ein wichtiger Aspekt ist neben der Erfassung auch die Analyse der Daten. Diese muss für die Anwendung in industriellen Prozessen voll automatisiert und entsprechend den Anforderungen ggf. in Echtzeit erfolgen. Da die betrachteten akustischen Methoden im Ultraschallbereich arbeiten, bilden diese aufgrund der großen Abstraten, im Vergleich zu vielen anderen Methoden zu Prozessüberwachung aktuell die anspruchsvollsten Anforderungen. Hierzu wird zurzeit ein generisches Framework zur Auswertung unterschiedlicher Prozessdaten entwickelt. Dies umfasst das echtzeitfähige Einlesen von Sensordaten, die Vorverarbeitung und Signalanalyse sowie die Interpretation der Daten basierend auf Methoden der künstlichen Intelligenz.

## 1 Einführung

Im Rahmen der industriellen Digitalisierung gewinnen datenbasierte Ansätze zur Prozessoptimierung, -steuerung, und -regelung immer mehr an Bedeutung. Datenbasierte Ansätze weisen gegenüber analytischen oder numerischen Ansätzen den Vorteil auf, dass komplexe Wirkzusammenhänge, die in vielen Fertigungsprozessen vorliegen, erfasst werden können, ohne diese explizit modellieren und beschreiben zu müssen. Für die datenbasierte Modellbildung werden aktuell zumeist Methoden des maschinellen Lernens eingesetzt. Diesen Methoden liegt zu Grunde, dass die zu beschreibenden Zusammenhänge in einem Datensatz vorliegen, der für die Erstellung des Modells verwendet wird. Basierend auf dieser Datenbasis

können beispielsweise Verfahren des überwachten Lernens für Klassifizierungs- und Regressionsprobleme sowie auch Verfahren des unüberwachten Lernens zur Mustererkennung oder Anomaliedetektion eingesetzt werden.

Zustands- und Prozessüberwachungssysteme bilden daher die Grundlage zur Erhebung von Daten für das Training und den Einsatz datenbasierter Modelle in der Produktion. Der Begriff Zustandsüberwachung umfasst nach DIN ISO 17359:2018 [1] alle Aktivitäten zur Bestimmung des technischen Zustands einer Maschine bzw. Anlage, während der Begriff der Prozessüberwachung insbesondere die Aktivitäten zur Beurteilung des Ablaufs eines Prozesses beinhaltet. Die Aktivitäten umfassen dabei in der Regel die Überwachung mittels geeigneter Sensorik, die Beurteilung des Zustands sowie die genaue Diagnose des Zustands. Im weiteren Sinne wird auch die Prognose eines Zustands z.B. für die vorausschauende Wartung der Zustands- und Prozessüberwachung zugeordnet.

Für die Prozessüberwachung kommen verschiedene Sensortechnologien und Datenformate in Frage. Diese umfassen neben Temperatur- und Kraft-Momenten-Sensoren auch schwingungsbasierte Messmethoden. Beispiele dafür sind Verfahren zur Überwachung mittels akustischer Festkörperwellen durch passive Verfahren wie z.B. Schallemissions- oder Körperschallanalyse sowie aktive Verfahren wie der Einsatz geführter Wellen oder Puls-Echo-Verfahren. Weitere schwingungsbasierte Ansätze basieren auf dem Einsatz von Beschleunigungssensoren. Insbesondere schwingungsbasierte Verfahren gehen mit einem nicht zu unterschätzenden Aufwand bei der Datenerfassung, Vorverarbeitung und Interpretation einher. Die anfallenden Schritte zur Erfassung und Bearbeitung der Daten sind jedoch auch für unterschiedliche zu überwachende Prozesse methodisch sehr ähnlich. Um die Synergien bei der Überwachung verschiedener Prozesse nutzen zu können, wurde das MATLAB basierte Framework „Ultra High Ultrasonics – UHU“ entworfen [2,3], das standardisierte Vorgehensweisen und Ansätze für die Datenverarbeitung von Zustandsüberwachungssystemen umfasst. Dieses Framework soll als Grundlage insbesondere für schwingungsbasierte Überwachungssysteme dienen und den Entwicklungsaufwand für neue Prozesse und Überwachungsszenarien minimieren. Im Folgenden soll zuerst die Weiterentwicklung des Frameworks und der dadurch neu strukturierte Umfang dargestellt werden. Anschließend werden exemplarische Einsatzmöglichkeiten des Frameworks an konkreten Beispielen und Vorhaben für die Prozessüberwachung aufgezeigt.

## 2 Software Framework

Das Framework soll die Möglichkeit bieten, den Prozess von der Datenerfassung bis zur Interpretation generalisiert abzubilden und für verschiedene Messprinzipien und Messsysteme zu synchronisieren. Die strukturierte Vorgehensweise soll dabei helfen, Mehrfachaufwände zu vermeiden. Neben der Nutzung synergetischer Effekte verschiedener Überwachungsszenarien gibt das Framework gleichzeitig eine klare Struktur zur Erstellung einer neuen Überwachungslösung vor. Die Struktur gliedert sich dabei in verschiedene Ebenen und ist schematisch in Abb. 1. dargestellt.

Die *Data Source* umfasst die Datenerfassung und wird von allen Datenquellen wie Messsystemen, Maschinen oder auch manuell hinzugefügten Daten gebildet. Neben den Messwerten werden Metadaten wie Abtastraten, Signalvorverstärkung etc. gesammelt. Im Falle eines neu in das Framework zu integrierenden Messsystems muss einmalig eine Einleसरoutine für das Messgerät bereitgestellt werden. Das Bereitstellen der Daten kann entweder offline zur Auswertung historischer Daten oder online erfolgen.

Die *Measurement*-Ebene dient als Interface und bietet dem Nutzer des Frameworks Möglichkeiten, die Datenverarbeitung im Framework problemspezifisch genauer zu definieren. Dort werden die weiteren Operationen, die auf der Ebene des *Data Controller* und in der

*Preprocessing*-Ebene erfolgen, vorgegeben und entsprechende Strategien zur Parallelisierung der Datenverarbeitung implementiert.

Der *Data Controller* beinhaltet die Einleseroutinen für unterschiedliche Messgeräte und Datenformate. Er nimmt vom Benutzer den Pfad zu den Messdateien, die ausgelesen werden sollen, entgegen und steuert, wieviel bzw. welcher Bereich von der Datei in den Arbeitsspeicher geladen/gelesen werden soll. Außerdem werden notwendige Header Daten initialisiert. Im Fall komplexerer mehrkanaliger Datenerfassungssysteme legt der Data Controller zudem die Datenkanäle fest, welche eingelesen werden sollen.

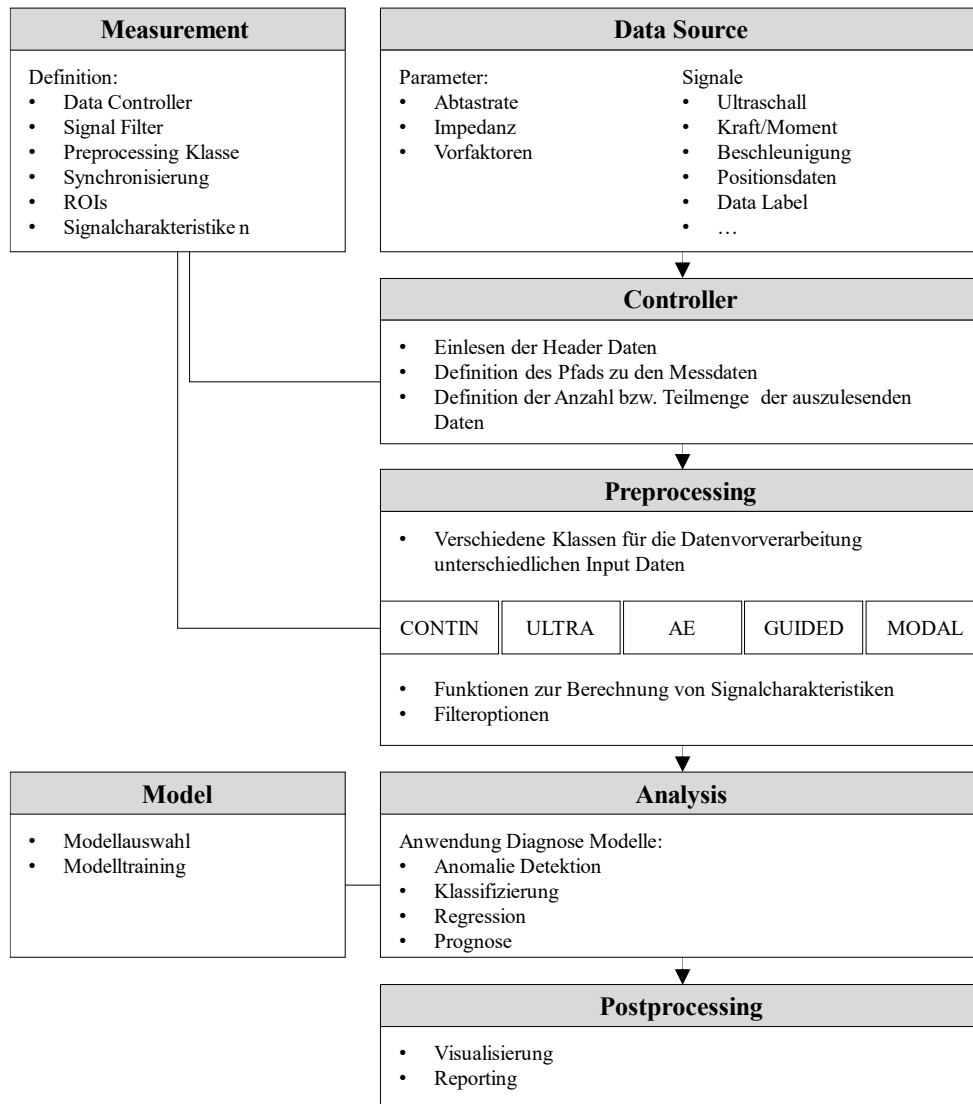


Abb. 1 Schematischer Aufbau des Frameworks zur Überwachung industrieller Fertigungsprozesse

Auf der *Preprocessing*-Ebene findet die Datenvorverarbeitung statt. Neben globalen Methoden zur Vorverarbeitung wie z.B. Filteroperationen ist die Datenvorverarbeitung abhängig von der Auswahl der *Preprocessing*-Klasse, die auf der *Measurement*-Ebene getroffen wird. Dabei wird aktuell grundsätzlich zwischen fünf verschiedenen *Preprocessing*-Klassen unterschieden:

- *CONTIN*: Analyse kontinuierlicher Datenströme
- *ULTRA*: Analyse von Impuls-Echo Messungen
- *AE*: Analyse von transienten Signalen insbesondere Schallemission
- *GUIDED*: Analyse der Daten aus Messungen mit geführten Wellen
- *MODAL*: Modalanalyse

Die aktuell am häufigsten verwendete Klasse im Rahmen der Prozessüberwachung für verschiedene Sensortechnologien ist die *CONTIN*-Klasse. Sie ist zur Analyse von kontinuierlichen Daten in Form von Zeitreihen und damit maßgeblich für die Körperschallanalyse oder kontinuierliche Schwingungszustandsüberwachung konzipiert worden. Die *ULTRA*-Klasse umfasst Funktionalitäten zur Signalverarbeitung für die aktive Ultraschallüberwachung mittels Transmissions- und Impuls-Echo-Verfahren. Die *AE*-Klasse umfasst die Analyse getriggert transienter Signale, die maßgeblich für die Schallemissionsanalyse sind. In der *GUIDED*-Klasse findet die Signalverarbeitung für die Prüfung mit geführten Wellen statt, während in der *MODAL*-Klasse Modalanalysen umgesetzt werden sollen. Die hier vorgestellten Inhalte beziehen sich auf die Forschung im Bereich der *CONTIN*- und der *ULTRA*-Klasse. In den einzelnen Klassen findet die Berechnung von klassenspezifischen Signalcharakteristiken, engl. Features, statt. Die Klassen beinhalten dafür ein breites Spektrum an vordefinierten Berechnungsvorschriften für Signalcharakteristiken aus dem Zeit- und Frequenzbereich, die auf der *Measurement* Ebene ausgewählt werden. Im Rahmen der Feature Berechnung basierend auf vordefinierten Zeitintervallen findet eine Reduktion der Daten statt. Während die extrahierten Merkmale gespeichert werden, können die Rohdaten des Streams verworfen werden, was bei Abstraten im MHz Bereich notwendig wird. Die Wahl der Zeitintervalle kann dabei maßgeblich das Überwachungsergebnis beeinflussen und muss daher sorgfältig gewählt werden. Das Ergebnis des *Preprocessing* stellt ein Vektor an Signalcharakteristiken dar, der für die weitere Auswertung genutzt werden kann.

Die Auswertung erfolgt auf der *Analysis* Ebene. Für die Analyse der Daten wird zunächst zwischen verschiedenen Problemkategorien unterschieden. In Frage kommen dafür insbesondere Klassifizierungs- und Regressionsprobleme sowie Methoden zur Anomaliedetektion. Zukünftig sollen auch Prognosemodelle im Framework aufgenommen werden. Für die Analyse werden geeignete Modelle aufgerufen. Input der Modelle bildet der Merkmalsvektor aus der *Preprocessing*-Ebene. Basierend auf dem ausgewählten Modell werden die im Merkmalsvektor zusammengefassten low-level Features zu höherwertigen Auswertungen in Form von Prozessinformationen weiterverarbeitet.

Für die Analyse werden passende Modelle zur Auswertung benötigt. Diese werden in der *Model*-Ebene generiert. Je nach Aufgabenstellung können als Modell sehr einfache analytische Beschreibungen mit Toleranzbändern eingesetzt werden. Bei akustischen Verfahren haben sich jedoch insbesondere Modelle des maschinellen Lernens zur Detektion von Anomalien und zur Lösung von Klassifizierungs- und Regressionsproblemen als stabile Verfahren erwiesen. Diese Modelle beinhalten im Rahmen von überwachten Lernverfahren immer die Modellauswahl und deren Trainingsprozess, sowie die Validierung der Modelle anhand von Testdaten. Diese Vorgänge finden in der Regel offline statt. Dennoch kann das vorgestellte Framework auch für die Modellerstellung bereits genutzt werden. Analog zu dem beschriebenen Vorgehen für die Überwachung werden sensorische Daten erfasst und bis zum Merkmalsvektor weiterverarbeitet. Parallel dazu werden Label-Daten über die *Measurement*-Ebene eingelesen und über Indizierung oder Zeitstempel dem zeitabhängigen Merkmalsvektor zugeordnet. Die gelabelten Daten werden dann für das Modelltraining und den Modelltest verwendet. Die Modellerstellung ist aktuell noch mit manuellem Aufwand verbunden, soll jedoch im Rahmen der Weiterentwicklung des Frameworks weiter automatisiert werden. Denkbar dafür sind Optimierungsalgorithmen, die bei der Definition der Zeitintervalle und Definition der Signalcharakteristiken unterstützen. Verfahren wie z.B. der Einsatz von Autoencodern soll helfen, relevante Signalcharakteristiken zu identifizieren und dadurch die Definition eines geeigneten bzw. optimierten Merkmalsvektors zu ermöglichen.

### 3 Anwendungsbeispiele

Das Zustands- und Prozessüberwachungsframework wird aktuell anhand konkreter Projekte und damit verknüpften industriellen Prozessen weiterentwickelt und wächst dabei immer weiter im Funktionsumfang. Die unterschiedlichen Prozesse stellen dabei verschiedene Anforderungen an das Softwareframework bezüglich Untersuchungsgegenstand, Echtzeitfähigkeit und Aufwand zur Datenverarbeitung und Analyse. Ziel des Frameworks ist es, ein breites Spektrum dieser Aufgaben zu erleichtern und langfristig für ausgewählte Prozesse in eine offene Softwarelösung überzugehen. Im Folgenden soll die Anwendung des Frameworks, mit Schwerpunkt auf der *CONTIN*- und *ULTRA*-Klasse, für die Überwachung unterschiedlicher industrieller Prozesse betrachtet werden.

#### 3.1 Werkzeugüberwachung in der Zerspanung

Im Umfeld der Zerspanung finden Zustandsüberwachungssysteme immer mehr Einsatz. Dafür sind unterschiedliche Überwachungssysteme und damit auch Messprinzipien oft bereits kommerziell verfügbar. Moderne Maschinen und Anlagen bieten außerdem die Möglichkeit, Daten aus der Maschinensteuerung für die Überwachung zu nutzen. Schwingungsbasierte Methoden wie z.B. die Körperschallanalyse gewinnen im Bereich Zerspanung trotz komplexer Datenauswertung immer mehr an Bedeutung und können vergleichbare oder teils überlegene Ergebnisse zu anderen Messsystemen erzielen. Typische Aufgaben der Prozessüberwachung sind dabei das Überwachen der Bauteilqualität und damit verbunden auch die Detektion von Prozessanomalien sowie die Onlineüberwachung und -prognose von Werkzeugzuständen. Bei der Weiterentwicklung des Frameworks wurde das Themenumfeld Zerspanung vor allem für den Workflow der *CONTIN*-Klasse detailliert betrachtet. Als Beispiel für den Einsatz des Frameworks soll hier die Überwachung des Werkzeugverschleißes beim Fräsen ausgeführt werden [10]. Dabei wurden Verschleißversuche an verschiedenen Materialien und unter Variation der Prozessparameter durchgeführt und mittels Körperschallsensoren überwacht. Exemplarisch ist das erfasste Zeitsignal in Abb. 2 dargestellt.




Abb. 2 Körperschallsignal bei der Fräsbearbeitung eines Chrom-Nickel Edelstahl mit dem Zeitfenster zur Berechnung des gleitenden Mittelwerts (links) der berechneten Signalcharakteristiken basierend auf vordefinierten Zeitintervallen (rechts).

Parallel dazu wurde die Verschleißmarkenbreite optisch mit einem Lichtmikroskop bestimmt. Aus den Körperschallsignalen wurden im Rahmen des Frameworks Signalcharakteristika berechnet. Tief- und Hochpassfilter helfen dabei, Störgeräusche, die nicht mit dem



Bearbeitungsvorgang korrelieren, zu entfernen. Entsprechend der Definitionen in der *Measurement*-Ebene wird das erfasste Signal in für die Auswertung relevante Zeitintervalle (Regions Of Interest, kurz ROI) und irrelevante Intervalle unterteilt. Dies kann im einfachsten Fall z.B. über Schwellwertverfahren der Sensorik erfolgen. Falls dies keine Stabile Lösung darstellt, können entweder Informationen aus der Maschinensteuerung oder anderen Messsystem herangezogen werden. Für die relevanten Bereiche findet eine Berechnung der Signalcharakteristiken entsprechend der *CONTIN*-Klasse statt. Dazu werden diskrete Subintervalle gebildet, auf deren Basis die Featureberechnung erfolgt. Die Wahl der Subintervalle ist abhängig von der jeweiligen Überwachungsaufgabe zu wählen. Für ein stabileres Überwachungsergebnis wird ein gleitender Mittelwert über die Ergebnisse der Zeitintervalle gebildet, siehe Abb. 2. Im Fall der Werkzeugüberwachung beim Fräsen wurde hier beispielsweise ein Wert von 500 ms mit einem resultierenden Überlapp von 250 ms und Subintervalle von 10 ms als sinnvoll erachtet. Unter Zuhilfenahme der lichtmikroskopischen Messungen wurden die Signalcharakteristika mit entsprechenden Verschleißmarkenbreiten gelabelt. Modelle basierend auf analytischen Zusammenhängen haben sich für die Auswertung als wenig stabil erwiesen [10]. Der gelabelte Merkmalsvektor wurde daher verwendet, um Regressionsmodelle des maschinellen Lernens zu trainieren. Die Diagnosequalität wurde anhand von Testdaten überprüft. Insbesondere Ensemble-Modelle wie das Boosted Ensemble Tree-Modell haben sich dabei als geeignet erwiesen [10]. Abb. 3 zeigt die Ergebnisse des Diagnosemodell im direkten Vergleich zu den mikroskopisch bestimmten Verschleißmarkenbreiten.




Abb. 3 Ergebnisse eines Regressionsmodells zur Bestimmung des Werkzeugverschleißes bei der Fräsbearbeitung eines Chrom-Nickel Edelfstahls [10].

Nach der Definition der Erfassungsparameter und Preprocessingparameter sowie eines geeigneten Diagnosemodells kann die Datenpipeline des Frameworks vom Entwicklungsprozess in ein echtzeitfähiges Überwachungssystem überführt werden. Ansätze zur Echtzeitüberwachung wurden dabei bereits getestet und haben sich als praktikabel erwiesen [4].

### 3.2 Fügetechnologien

Unter 3.1 wurde die Analyse insbesondere auf die Überwachung des Werkzeugs ausgelegt. Vor allem beim Fügen von Bauteilen liegt ein Schwerpunkt der Zustandsüberwachung jedoch auch bei der Beurteilung der Qualität der Schweißnaht, da diese zumeist sicherheitsrelevant für die jeweilige Anwendung ist. Das Thema Anomaliedetektion und Defektbewertung im Kontext des Softwareframeworks soll daher insbesondere im Rahmen von Fügeverfahren weiter erforscht und entwickelt werden. Aktuell wird hierzu als Fügeverfahren der

Rührreibschweißprozess (engl. Friction Stir Welding, kurz FSW) als weiteres Verfahren untersucht. Bislang finden sich dazu insbesondere Forschungsarbeiten, die zwar auf eine Prozessüberwachung hinarbeiten, jedoch keine konkreten Aussagen über die genaue Lage, Defektklassifizierung sowie auch -quantifizierung erlauben. Daher besteht v. a. in den Bereichen der Online-Quantifizierung sowie der Lokalisierung von Schweißnahtdefekten beim FSW eine Forschungslücke [5]. Mishra et al. [6] sehen vor allem das Potential bei der Auswertung von akustischen Überwachungsdaten durch die Auswertung von spezielleren Features aus dem Zeit- und Frequenzbereich und der Nutzung dieser Features zum Trainieren neuronaler Netze. Dies soll künftig durch den Einsatz des beschriebenen Frameworks umgesetzt werden. Dazu fanden bereits Voruntersuchungen zur echtzeitfähigen Anomaliedetektion statt. Diese wurden anfänglich noch an Fräsprozessen getestet und sollen zukünftig an die Anforderungen im FSW-Prozess ausgebaut werden [4].

Als Fallbeispiel für die Anomaliedetektion wurden während der Fräsbearbeitung einer Aluminiumplatte Körperschallsignale mit einer Abtastrate von 1 MHz erfasst und entsprechend der Datenpipeline des Frameworks bis zu relevanten Signalcharakteristiken vorverarbeitet. Werkstückseitige Anomalien wurden simuliert, indem im Vorfeld des Versuchs Bohrlöcher in die Platte eingebracht wurden. Da die einzeln betrachteten Signalcharakteristiken schwer interpretierbar sind, wurden diese in höherwertige Information weiterverarbeitet. In diesem speziellen Beispiel lag die höherwertige Information in der Erkennung von werkstückseitigen Anomalien. Dazu wurde ein Autoencoder eingesetzt [4].

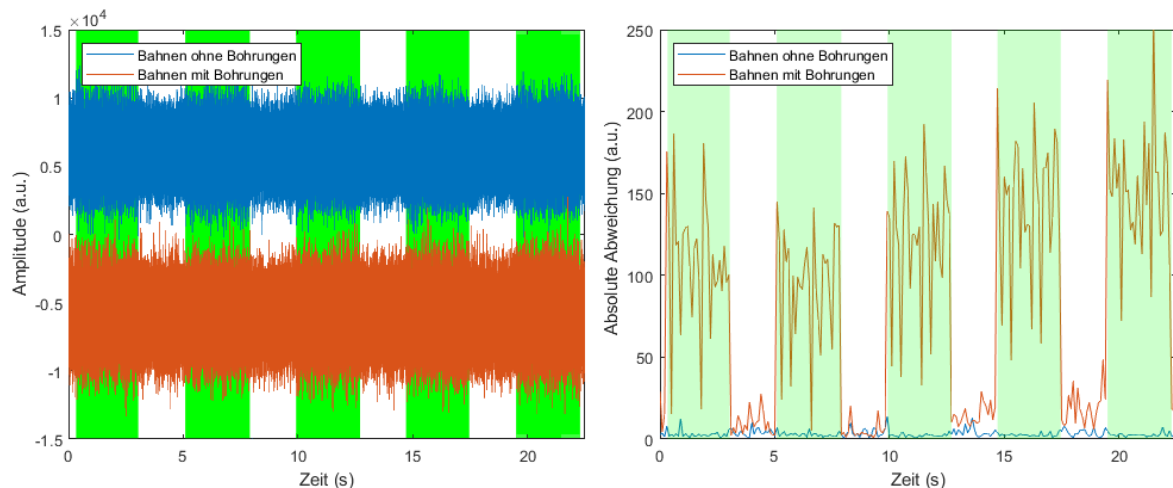


Abb. 4 Detektion einer werkstückspezifischen Anomalie in Form einer Bohrung bei der Schlichtbearbeitung einer Aluminiumlegierung mit dem Rohsignal mit und ohne Bohrungen (links) und dem Rekonstruktionsfehler des Autoencoders zur Anomalieerkennung (rechts) [4]. Die Zeitabschnitte in der Region der Bohrungen sind dabei Grün markiert.

Dabei werden die Signalcharakteristiken zum Training eines sich selbst abbildenden neuronalen Netzes verwendet, welches durch eine Verengung seiner Netzwerkstruktur eine Reduktion bzw. Enkodierung der Daten erzwingt und versucht, mittels anschließender Dekodierung die enkodierten Daten als Ausgabe wiederherzustellen. Die erlernten Zusammenhänge der Inputdaten und deren Rekonstruktion verläuft für die normalen, antrainierten Fälle in der Regel ohne große Rekonstruktionsfehler ab. Für Anomalien gelten diese Zusammenhänge nicht mehr zwangsläufig und es entsteht ein Rekonstruktionsfehler, der zur Erkennung von Anomalien verwendet werden kann [7]. Durch dieses Verfahren können, wie in Abb. 4 dargestellt, Prozessabweichungen aus einer komplexen Kombination von Signalcharakteristiken erkannt werden. Die demonstrierte Vorgehensweise soll dem Grundgedanken nach zukünftig für die Überwachung beim FSW adaptiert werden. Dazu sollen in weiteren Arbeiten geeignete Signalcharakteristiken definiert, Zeitintervalle gewählt und Sensorkombinationen getestet werden.

### 3.3 Kunststoffverarbeitung

In Abschnitt 3.1 und 3.2 wurde insbesondere die Entwicklung der *CONTIN*-Klasse anhand von Fallbeispielen adressiert. Neben dieser wurde die Entwicklung des Frameworks anhand der *ULTRA*-Klasse zur Überwachung mittels aktiver Ultraschallsensorik weiterentwickelt. Die Arbeiten basieren insbesondere auf dem von F. F. Linscheid [3] entwickelten Messsystem, konzipiert zur Überwachung eines T-RTM (Resin Transfer Molding) Prozesses. Das Überwachungssystem ist daher vor allem für den Einsatz in der Kunststoffverarbeitung vorgesehen. Grundlage des Messprinzips bildet hier eine aktive Anregung eines Impulses im Ultraschallbereich über ein piezoelektrisches Element. Dazu wird ein Sensor, der als Empfänger und Sender dient, an einer Struktur angekoppelt, die im späteren Verlauf für die Formgebung (z.B. Werkzeugform beim Spritzguss, RTM, Infusion, u.v.m.) oder Dosierung (z.B. Klebedüse) in der Verarbeitung verantwortlich ist. Die vom Pulsgeber emittierte Welle wird an den jeweiligen Grenzflächen teilweise transmittiert und reflektiert, wie in Abb. 5 dargestellt. Der reflektierte Signalanteil kann vom Sensor anschließend erfasst und zur Überwachung genutzt werden.





Abb. 5 Schematische Darstellung der Ausbreitung der Schallwelle eines aktiven Transducers an einer Werkzeugform (links). Zeitlicher Verlauf der spektralen Energiedichte für einen optimierten Frequenzbereich im Vergleich zur mittels Rheometer gemessenen komplexen Viskosität (rechts) [11].

Der Reflexionsfaktor der Grenzflächen bestimmt dabei den Anteil des reflektierten Signals und hängt maßgeblich von dem Verhältnis der akustischen Impedanz der Grenzflächenmedien und somit der Dichte und Schallgeschwindigkeit der Medien ab [8]. Ändern sich Materialeigenschaften oder Struktur des Polymers bzw. der Inhalt der Werkzeugform, hat dies in Teilen des aufgezeichneten Signals eine Änderung zur Folge. Im Rahmen der *ULTRA*-Klasse können deshalb die ROIs zur Auswertung der Signale so definiert werden, dass nur vorgegebene Zeiten nach der Impulserzeugung ausgewertet werden. Zur weiteren Signalverarbeitung können aufgabenspezifisch unterschiedliche Strategien angewandt werden.

Die erste Strategie ist zur Überwachung der Fließeigenschaften und damit auch zur Analyse von Polymerisationsgraden oder Erstarrungsgraden geeignet. Die Analyse ist eng verwandt mit der Analyse der *CONTIN*-Klasse. Dabei werden die Rückwändechos (in speziellen Fällen ist auch die Messung in Transmission mit einem zweiten Sensor möglich) der Signale detailliert im Zeit- und Frequenzbereich analysiert. Einige der Signalcharakteristiken zeigen dabei gute Korrelationen mit Viskositätsänderungen z.B. während Polymerisationsreaktionen [11], wie in Abb. 5 dargestellt. Dazu wurden bereits Verfahren zur Optimierung der Berechnung der Signalcharakteristiken untersucht. Auf dieser Grundlage sollen in weiteren Untersuchungen über geeignete, analytische und datenbasierte, Modelle quantitative Messungen der Fließeigenschaften realisiert und in das Framework integriert werden.

Als zweite Strategie hat sich die Überwachung des Fließverhaltens in geschlossenen Werkzeugformen über Sensornetzwerke basierend auf dem vorgestellten Impuls-Echo-Verfahren



bewährt. Dabei wird über den zeitlichen Verlauf geeigneter Signalcharakteristiken festgestellt, ob die Sensorposition bereits benetzt wurde. Dieses Verfahren kann vorzugsweise schwellwertbasiert ausgewertet werden. Eine Interpolation der Ergebnisse zur Fließfrontrekonstruktion wurde über Ansätze der Graphentheorie realisiert [9].

## 4 Zusammenfassung und Ausblick

Im Rahmen verschiedener Arbeiten zur Prozessüberwachung unterschiedlicher industrieller Prozesse wurde ein Framework konzipiert, das den Prozess zur Entwicklung von Software für neue Überwachungssysteme insbesondere basierend auf akustischen Messverfahren vereinfachen soll. Das Framework bildet dabei die gesamte Datenpipeline von der Erfassung bis zum Reporting der Ergebnisse ab. Der Einsatz des Frameworks wurde im Rahmen dieser Arbeit an verschiedenen Fallbeispielen demonstriert. Zukünftig soll ein Rollout der Vorgehensweise auf weitere Prozesse sowie eine weitere Ausarbeitung der Algorithmen des Frameworks erfolgen. Insbesondere die automatisierte Optimierung des Feature Engineerings in Kombination mit Modellauswahl und -training soll den nächsten Schritt bei der Entwicklung des Frameworks darstellen.

## 5 Danksagung

Dieser Beitrag stellt ein übergeordnetes Framework zur Prozessüberwachung dar. Entsprechend gilt der Dank allen, die zur Finanzierung der Arbeiten beigetragen haben. Dies umfasst das Bundesministerium für Bildung und Forschung im Rahmen des Projekts „WiR Augsburg - Wissenstransfer Region Augsburg“ im Programm „Innovative Hochschule“, den Freistaat Bayern in den Projekten „MAI CC4 fastMOVE“ und „MAI CC4 CosiMo“ im Rahmen des Programms „Neue Werkstoffe“ sowie die Kompetenzzentrum Mittelstand GmbH für die Finanzierung im Rahmen des Projektes „SmartCut“.

## 6 Referenzen

- [1] DIN ISO 17359 : 2018, Zustandsüberwachung und -diagnostik von Maschinen - Allgemeine Anleitungen Beuth-Verlag, Berlin, 2018.
- [2] F. F. Linscheid und M. G. R. Sause, 2021, Hard- und Softwarefusion von mehreren akustischen Messmethoden zur Zustandsüberwachung. In DGZfP Jahrestagung 2021 (virtuell): Materialcharakterisierung, 10. - 11. Mai 2021.
- [3] F. F. Linscheid, Entwicklung eines Zustandsüberwachungssystems durch Kombination von akustischen Überwachungsverfahren. Dissertation, 2022, Universität Augsburg
- [4] Q. R. Luong, T. Schlech, F. F. Linscheid, M. Achzet, M. G. R. Sause, Echtzeitfähige Analyse hochfrequenter Ultraschalldaten zur Überwachung von Fertigungsprozessen, In DGZfP Schall 23, Zustandsüberwachung Fertigungsprozesse, 21.-22 März, 2023, Wetzlar
- [5] S. A. Babalola, N. Kumar, S. Dutta, N. C. Murmu und M. Chandra, „Recent Trends in Manufacturing and Materials Towards Industry 4.0. Lecture Notes in Mechanical Engineering, Springer,“ in A Critical Review on the Trends Toward Effective Online Monitoring of Defects in Friction Stir Welding of Aluminum Alloys, Singapore, 2021.
- [6] D. Mishra, R. B. Roy, S. Dutta, S. K. Pal und D. Chakravarty, „A review on sensor-based monitoring and control of friction stir welding process and a roadmap to Industry 4.0,“ Journal of Manufacturing Processes 36, pp. 373-397, 2018.
- [7] Jakovlev, S.; Voznak, M. Auto-Encoder-Enabled Anomaly Detection in Acceleration Data: Use Case Study in Container Handling Operations. Machines 2022, 10, 734
- [8] Krautkrämer, J. and H. Krautkrämer, Werkstoffprüfung mit Ultraschall. 2013: Springer-Verlag.
- [9] M. Achzet, T. Schlech, F. F. Linscheid, J. Faber und M. G. R. Sause, Ultraschallbasierte Prozessüberwachung am Beispiel eines T-RTM Prozesses in: DGZfP-Jahrestagung 2022, Kassel, 23.-25. Mai 2022, 1-11
- [10] C. Baumeister, T. Schlech, M. Achzet, Q. R. Luong, F. F. Linscheid, B. Brück, M. G. R. Sause 1, Akustische Überwachung des Werkzeugverschleißes bei der zerspanenden Bearbeitung, In DGZfP Schall 23, Zustandsüberwachung Fertigungsprozesse, 21.-22 März, 2023, Wetzlar
- [11] M. Achzet, B. Schaller, T. Schlech, F. F. Linscheid, M. G. R. Sause, Ultraschallbasierte Untersuchung rheologischer Eigenschaften von Polymeren für die Prozessüberwachung, In DACH-Jahrestagung 2019: Materialcharakterisierung, 15. - 17. Mai 2023, Friedrichshafen. Deutsche Gesellschaft für Zerstörungsfreie Prüfung (DGZfP), Berlin