

Detaillierte Ergebnisse – Teilprojekt

Automatische Modellierung spanender Fertigungsprozesse

DIGITALER ZWILLING

FORSCHUNGSSINTERESSE:

- Wie kann das Fräsen im Werkzeug- und Formenbau optimiert werden, um die Herstellung kostenintensiver Einzelfertigungen zu verbessern?
- Wie können Formabweichungen frühzeitig vorhergesagt werden, um Kosten zu sparen und die Wirtschaftlichkeit zu steigern?

VORGEHEN:

- Die Wissenschaftler*innen erstellten einen digitalen Zwilling der Fräsmaschine, die die Gießform des Aluminiumdruckgusses herstellt.
- Für die Erstellung des digitalen Zwillingss analysierten die Wissenschaftler*innen die Maschinensteuerungen zur digitalen Abbildung der Maschinenachsen und ihrer Konfiguration.
- Zudem entwickelten sie ein Programm zum automatischen Auslesen und Interpretieren relevanter Informationen aus der Maschinensteuerung.
- Daraufhin verglichen sie verschiedene Modelle der Künstlichen Intelligenz hinsichtlich Vorhersagegenauigkeit und Rechenaufwand.
- Anschließend führten die Wissenschaftler*innen Simulationen und Experimente zur Vorhersage von Formabweichungen und Verschleiß mithilfe der KI-Modelle durch. Die Datensätze beinhalteten diverse, mithilfe des digitalen Zwillingss simulierte Prozessgrößen wie Zeitspanvolumen und Eingriffsbreite, sowie detailliertere Informationen zur bearbeiteten Kontur, Krümmung des Schnittes und dem Werkzeugverschleiß.
- Schließlich validierten sie die Ergebnisse durch Versuchsreihen mit unterschiedlichen Rahmenbedingungen.

ERGEBNISSE/ERKENNTNISSE:

- Die KI-Modelle konnten erfolgreich Vorhersagen für Formabweichungen treffen, wobei sich herausstellte, dass zusätzliche Messgrößen die Prognosegenauigkeit weiter verbessern.
- Die Forschung zeigte, dass sich digitale Zwillinge und KI-Modelle gut für die Qualitätsprognose in der Zerspanung eignen.

GENAUIGKEIT UND ERKLÄRBARKEIT VON MACHINE-LEARNING-MODELLEN

FORSCHUNGSSINTERESSE:

- Wie kann die Genauigkeit und die Erklärbarkeit von ML-Modellen zur Prognose von Formabweichungen verbessert werden?
- Wie können ML-Modelle angeben, wie sicher sie mit ihren Prognosen sind?

VORGEHEN:

- Die Wissenschaftler*innen nutzten Machine Learning, um sogenannte Surrogatmodelle zu erzeugen: Modelle, die mit Daten aus der Prozesssimulation und empirischen Qualitätsdaten trainiert werden, um die Qualität (z. B. Formabweichungen oder Oberflächengüte) von weiteren Gießformen vor der Herstellung vorherzusagen. Diese Modelle können auch für wechselnde Geometrien, wie sie im Formenbau üblich sind, Prognosen tätigen.
- Bei den meisten Modellen ist allerdings nicht ersichtlich, wie hoch die Stichproben von den zu erwarteten Ergebnissen abweichen werden, da diese für unterschiedliche Eingriffsbedingungen innerhalb des gleichen Bauteils stark variieren kann.
- Deshalb entwickelten die Wissenschaftler*innen eine Methode, die in Abhängigkeit der Datenlage und der zugrundeliegenden Varianz ein Konfidenzintervall für neue Prognosen ausgibt. Ein Konfidenzintervall ist ein Maß dafür, wie sicher bzw. unsicher eine Schätzung eintritt - in diesem Fall die prognostizierte Formabweichung

ERGEBNISSE/ERKENNTNISSE:

- Die Methode gibt Aufschluss darüber, mit welcher Wahrscheinlichkeit eine bestimmte Abweichung der geplanten Form eintritt, je nachdem welche Einstellung vor dem Fertigungsprozess vorgenommen werden (z. B. Schnitttiefe, Schnittgeschwindigkeit, Zeitspanvolumen).
- Die Methode trägt zur Erklärbarkeit von Machine-Learning-Modellen bei, indem sie die Unsicherheit der Ergebnisse transparent macht und die Vorhersagen dadurch nachvollziehbar werden.

MACHINE-LEARNING-MODELLE IM TEST

FORSCHUNGSSINTERESSE:

- Welche ML-Modelle liefern zuverlässige Prognosen zum Herstellungsprozess des Gießwerkzeuges?
- Welche Datengrundlage ist für die Modelle erforderlich?

VORGEHEN:

- Die Wissenschaftler*innen simulierten den Herstellungsprozess des Gießwerkzeugs mithilfe eines digitalen Zwillingss, der die Auswirkungen verschiedener Parameter (z. B. Schnitttiefe) auf die Qualität des Produkts widerspiegelt.
- Daraufhin passten die Wissenschaftler*innen die Parameter im virtuellen Prozess so lange an, bis das virtuelle Gießwerkzeug die gewünschten Eigenschaften erreichte.
- Anschließend testeten die Wissenschaftler*innen verschiedene Machine-Learning-Modelle, um deren Effizienz in der Qualitätsprognose zu evaluieren und herauszufinden, wie viele und welche Daten sie benötigen.

- Die Wissenschaftler*innen untersuchten z. B., wie sich die Vorhersage der Modelle verändert, wenn die Daten eines Sensors aus den Trainingsdaten entfernt werden.

ERGEBNISSE/ERKENNTNISSE:

- Die Forschung zeigte, dass Machine Learning erfolgreich zur Verbesserung der Produktqualität im Aluminiumdruckguss eingesetzt werden kann.
- Durch die Analyse der Sensordaten wurde deutlich, welche Sensoren entscheidend zur Fehlererkennung beitragen und somit gewinnbringend in den Produktionsprozess integriert werden sollten. Dies hilft Unternehmen, fundierte Entscheidungen über den Einsatz und die Integration von Sensoren zu treffen, um Effizienz und Produktqualität zu steigern.

AUSWIRKUNGEN DES WERKZEUGVERSCHLEIßES AUF DIE ML-PROGNOSSEN

FORSCHUNGINTERESSE:

- Wir wirkt sich der Werkzeugverschleiß bei der spanenden Verarbeitung auf die Qualität der ML-Prognosen aus?
- Welche Messgrößen sind für die Prognosequalität relevant, wenn ein neues oder verschlissenes Werkzeug verwendet wird?

VORGEHEN:

- Die Wissenschaftler*innen prüften, mit welchen Prozessmerkmalen die Formfehler, die aus dem Verschleiß entstehen, vorhergesagt werden können.
- Als Datengrundlage nutzten sie Simulationsdaten, Prozesskräfte und Antriebsströme. Auf Basis dieser Daten prognostizierte das Modell die Auswirkung des Werkzeugverschleißes auf die Formabweichungen des Bauteils.
- Darüber hinaus hinterfragten die Wissenschaftler*innen, ob die Vorhersagemodele noch ausreichend gute Prognosen treffen, wenn das Fräswerkzeug bereits einem Verschleiß unterliegt.
- Des Weiteren hinaus analysierten sie, wie sich Modelle verändern, wenn sie mit Daten eines verschlissenen Werkzeugs trainiert und dann auf ein neues Werkzeug angewendet werden. Hierzu verglichen die Wissenschaftler*innen die Prozesskräfte (Kräfte, die auf das Fräswerkzeug wirken) und die Spindelströme (sie treiben den Fräser an) miteinander und prüften, welche Messgrößen darüber hinaus notwendig sind, um im beschriebenen Szenario eine akzeptable Vorhersage zu treffen.

ERGEBNISSE/ERKENNTNISSE:

Die Wissenschaftler*innen fanden heraus, dass die prozessnahen Messungen der Prozesskräfte und Spindelströme zu genaueren Abbildungen der verschleißbedingten Formfehler führen können. Mit der zusätzlichen Berücksichtigung der Spindelströme kann die Prognosegüte gegenüber der Modellierung durch Simulationsdaten stark erhöht werden, ohne dass zusätzliche kostenintensive Sensoren (wie z. B. Kraftmessplattformen) in die Maschine integriert werden müssen. Die Daten der Kraftmessplattform konnten die Prognosegüte in den Untersuchungen jedoch geringfügig weiter verbessern.

ARBEITSERLEICHTERUNG DURCH ACTIVE LEARNING

FORSCHUNGINTERESSE:

- Welche Daten benötigt das Prognosemodell, um zuverlässige Aussagen zur Qualität des Gießwerkzeuges zu treffen?
- Wie kann die zeit- und arbeitsintensive Aufbereitung der Daten reduziert werden?

VORGEHEN:

- Die Wissenschaftler*innen untersuchten den Einsatz von Active Learning. Dies beschreibt eine Form des Machine Learnings, bei der das Modell signalisiert, dass die Datengrundlage für eine Prognose unzureichend ist und weitere Daten benötigt werden.
- Die Datenaufbereitung (sog. Labeling) geschieht in den meisten Fällen manuell, was sehr zeitintensiv ist. Wenn bekannt ist, welche Daten das Modell für die Qualitätsprognose benötigt, können diese zielgenau erfasst und gelabelt werden.
- Im Zukunftslabor Produktion erfasst der maschinenintegrierte Messtaster zahlreiche Messdaten. Die Wissenschaftler*innen prüften im Rahmen des Active Learnings, welche dieser Messdaten relevant sind und ob die Datenerfassung optimiert werden kann.
- Um das Prognosemodell zu trainieren, nutzten die Wissenschaftler*innen Daten aus vergangenen Produktionsprozessen. Dazu gehören einerseits die Schnittbedingungen (z. B. die Schnitttiefe und -breite des Fräzers im Bauteil), die im Rahmen der Prozessplanung eingestellt werden. Zudem umfassen die Trainingsdaten die Formabweichungen bereits hergestellter Bauteile, die durch die Qualitätssicherung ermittelt wurden.
- Neben den Daten vergangener Herstellungsprozesse nutzten die Wissenschaftler*innen auch Daten aus der eigenen Produktion. Dafür frästen sie eigene Bauteile und erfassten entstandene Formfehler. Im Anschluss trainierten sie das Prognosemodell mit den neu gewonnenen Daten und ließen wiederum eine Vorhersage der Formfehler erstellen. Um zu prüfen, ob das Modell die Zusammenhänge zwischen Eingangsbedingungen und Formabweichungen erkennt, verglichen die Wissenschaftler*innen die Vorhersage des Modells mit dem tatsächlichen Bauteil. Insgesamt führten sie den Vergleich zehn Mal durch, sowohl für geringe als auch für hohe Formabweichungen.
- Zudem bewerteten sie die Konfidenz des Active-Learning-Modells: Sie überprüften, wie sicher das Modell mit seinen Vorhersagen ist, und identifizierten Situationen, in denen zusätzliche Daten erforderlich sind.

ERGEBNISSE/ERKENNTNISSE:

- Die Wissenschaftler*innen stellten fest, dass Active Learning eine effiziente Methode ist, um die Datenerfassung und -aufbereitung gezielt zu steuern.
- Der Vergleich der Modellvorhersagen mit dem tatsächlichen Bauteil zeigte, dass das Active-Learning-Prognosemodell die tatsächlichen Formfehler gut vorhersagte.
- Auf Basis der beiden Datenquellen (Schnittbedingungen und Formabweichungen) kann das ML-Modell die Formabweichungen unter Angabe einer Konfidenz vorhersagen.
- Das Modell kann bei Unsicherheit zusätzliche Daten anfordern, wodurch unnötige Datenerhebung vermieden und die Datenmenge reduziert wird. Dies spart Zeit und Ressourcen bei der Qualitätsprognose und verbessert die Genauigkeit der Vorhersagen.