

Intelligente Prozessüberwachung für die flexible Produktion

Integration von Physics-Informed Machine Learning und Active Learning

Robin Ströbel,
Hafez Kader,
Louisa Hutt,
Hanlin Zhou,
Marcus Mau,
Alexander Puchta,
Benjamin Noack und
Jürgen Fleischer*

In einer individualisierten Produktion mit hoher Variantenvielfalt stoßen traditionelle Ansätze zur Prozessüberwachung immer häufiger an ihre Grenzen. Diese basieren meist auf statischen Datensätzen oder wiederkehrenden Prozessmustern, was in dynamischen Produktionsumgebungen zu ungenauen Vorhersagen und vermehrten Fehlalarmen führen kann. In diesem Beitrag wird ein Konzept zur Flexibilisierung der Prozessüberwachung diskreter Produktionsprozesse vorgestellt, das auf der Kombination von Physics-informed Machine Learning (PIML) und Active Learning (AL) basiert. In agilen Produktionsumgebungen können so nicht nur Anomalien erkannt, sondern das Überwachungsmodell bei Fehlalarmen auch automatisch aktualisiert werden. Dadurch bleibt das Überwachungssystem auch unter variablen Produktionsbedingungen präzise, was Fehlalarme reduziert und damit zu einer verbesserten Overall Equipment Effectiveness (OEE) beiträgt.

Neue Herausforderungen durch Fachkräftemangel und agile Produktionsumfelder

Produzierende Unternehmen stehen vor großen Herausforderungen: Fachkräftemangel, steigende Lohn- und Produktionskosten, dem Trend zur Individualisierung sowie zunehmendem internationalen Kos-

tendruck. Damit Unternehmen in diesem Umfeld wettbewerbsfähig bleiben, müssen neue Ansätze und Lösungen in der Produktion Einzug halten. Eine kostengünstige Produktion mit hoher Qualität und Flexibilität ist der Schlüssel zu einer zukunftsfähigen Wertschöpfung und damit zur langfristigen Sicherung der Wettbewerbsfähigkeit im globalen Markt [1].

Getrieben durch den Fachkräftemangel [2] kommt es jedoch zu einer Ausweitung von Aufgabenbereichen, sodass sich auch die Anzahl der zu überwachenden Maschinen erhöht. Wird ein kritischer Wert überschritten, sinkt jedoch die Effizienz von Mensch und Maschine [3], was langfristig zu Qualitätseinbußen und monetären Verlusten in der Produktion führen kann. Insbesondere bei hoher Auslastung können nicht mehr alle Prozesse kontinuierlich überwacht werden, sodass Systeme zur Prozessüberwachung unabdingbar sind.

Aufgrund des Trends hin zur Individualisierung von Produkten steigt der Anteil der Einzel- und Kleinserienfertigung an [1]. In diesem Umfeld stehen Prozessdaten nicht in einem geeigneten Umfang für eine statistische Überwachung zur Verfügung. Infolgedessen sind neue, flexiblere Ansätze erforderlich. Moderne Prozessüberwachungssysteme müssen in der Lage sein, komplexe Zusammenhänge präzise abzubilden. Sie müssen sich flexibel an unterschiedliche, sich wandelnde

* Korrespondenzautor

Robin Ströbel, M. Sc.; Institut für Produktionstechnik (wbk) am Karlsruher Institut für Technologie (KIT); Kaiserstr. 12, 76131 Karlsruhe; Tel.: +49 (0) 1523 9502603, E-Mail: robin.stroebl@kit.edu

Weitere Autor:innen

Hafez Kader, M. Sc.; AMS an der Otto-von-Guericke-Universität Magdeburg

Louisa Hutt, B. Sc.; wbk am Karlsruher Institut für Technologie

Hanlin Zhou, B. Sc.; wbk am Karlsruher Institut für Technologie

Marcus Mau, M. Sc.; wbk am Karlsruher Institut für Technologie

Alexander Puchta, M. Sc.; wbk am Karlsruher Institut für Technologie

Prof. Dr.-Ing. Benjamin Noack; Fakultät für Informatik der Otto-von-Guericke-Universität Magdeburg

Prof. Dr.-Ing. Jürgen Fleischer; wbk am Karlsruher Institut für Technologie

Hinweis

Bei diesem Beitrag handelt es sich um einen von den Advisory-Board-Mitgliedern des ZWF-Sonderheftes wissenschaftlich begutachteten Fachaufsatz (Peer Review).

Produktspektren und deren individuelle Prozessbedingungen anpassen und dabei möglichst dateneffizient arbeiten.

Im vorliegenden Artikel erfolgt eine Bewertung bestehender Ansätze aus Industrie und Wissenschaft. Aufbauend wird ein Konzept für ein Überwachungssystem am Beispiel des Fräsprozesses vorgestellt, welches Physics-Informed Machine Learning (PIML) und Active Learning (AL) integriert, um eine kontinuierliche Anpassung und Optimierung an sich ändernde Produktionsbedingungen zu ermöglichen.

Einordnung und Bewertung industrieller Lösungen für die Prozessüberwachung

Zur Beurteilung der Branchensituation wurden drei der umsatzstärksten deutschen Werkzeugmaschinenhersteller im Bereich der spanenden Bearbeitung bezüglich ihrer beworbenen Lösungen betrachtet: die DMG MORI AG, die Maschinenfabrik Berthold Hermle AG sowie die Chiron Group SE [4]. Die Bewertung und Einordnung der einzelnen Technologien zur Prozessüberwachung erfolgen anhand der folgenden Kriterien:

■ Zeitlicher Auflösungsgrad

Das System muss in der Lage sein, Prozesse mit einem hohen zeitlichen Auflösungsgrad zu überwachen. Somit muss es eine große Anzahl von Zeitpunkten pro Zeiteinheit vorhersagen, um detaillierte und hochfrequente Überwachungen sicherzustellen.

■ Robustheit

Das System muss robust gegenüber unvollständigen, ungenauen oder fehlerhaften Daten sein und auch unter diesen Bedingungen eine hohe Vorhersagegenauigkeit gewährleisten.

■ Anpassungsfähigkeit

Das System muss in der Lage sein, sich effizient an Prozessänderungen anzupassen, beispielsweise bei einer wandelnden Produktpalette, um auch unter veränderten Produktionsbedingungen eine zuverlässige Überwachung gewährleisten zu können.

■ Dateneffizienz

Das Überwachungsmodell muss die verfügbaren Daten effizient nutzen und in der Lage sein, möglichst viele Informationen aus den vorhandenen

Datensätzen zu extrahieren, um optimale Ergebnisse zu erzielen.

Die in Bild 1 dargestellte Übersicht gibt Aufschluss über alle Technologien, für die umfangreiche Informationen verfügbar sind. Die Einordnung erfolgt anhand der definierten Kriterien auf qualitativer Basis und berücksichtigt die unterschiedlichen Informationslagen. Ein niedriger Erfüllungsgrad entspricht einer starren Prozessüberwachung, die einfache und wiederkehrende Zusammenhänge abbildet. Ein hoher Erfüllungsgrad steht für die Vision einer flexiblen Prozessüberwachung.

Chiron bietet unter dem Namen *SmartLine* (A) eine Gesamtlösung an, die sich aus verschiedenen digitalen Bestandteilen zusammensetzt. Die folgenden *SmartLine*-Bausteine sollen unter anderem dabei helfen, Prozesse zu überwachen [5].

Der Baustein *ProcessLine* simuliert den realen Bearbeitungsprozess anhand eines digitalen Zwillings, der die Geometrie, die Kinematik sowie die Dynamik eines gesamten Bearbeitungszentrums abbildet. Dadurch können beispielsweise Rüstzeiten optimiert werden, ohne die Maschine dabei zu blockieren. Aufbauend soll der Baustein *ProtectLine* durch einen Abgleich der realen und simulierten Werkstückgeometrie während der Prozesse zuverlässig vor Produktionsausfällen schützen. Da der digitale Zwilling im Falle eines Maschinen-crashes zuerst kollidiert, kann die Maschine sicher zum Stillstand geführt werden. Dies soll einen präventiven und zuverlässi-

gen Schutz vor Produktionsausfällen gewährleisten. Um Prozesse kontinuierlich zu optimieren, erfasst und analysiert *DataLine* Maschinendaten parallel zum Prozess. Diese integrierte Maschinen- und Prozessdiagnose bietet eine Grundlage für die stetige Verbesserung des gesamten Prozesses bezüglich Hard- und Software, Automatisierung sowie Prozess- und Rüstzeiten. Mit dem Baustein *ConditionLine* sollen durch die permanente Maschinendatenerfassung und -analyse frühzeitig Unregelmäßigkeiten erkannt werden, sodass Wartungen und Reparaturen proaktiv und zugeschnitten auf die eigene Produktion geplant und durchgeführt werden können, um zeit- und kostenintensive Stillstände zu vermeiden [5].

Insgesamt weisen die Bausteine zur Prozessüberwachung von *SmartLine* (A) eine niedrige Dateneffizienz auf. Für jeden Prozess müssen konkrete Daten vorliegen, sodass die Robustheit des Modells sowie die Anpassungsfähigkeit einzelner Modelle als eher niedrig eingestuft werden können. Durch die Prozesssimulation mit dem digitalen Zwilling ist bereits eine Lösung mit hochfrequentem Auflösungsgrad gegeben.

Hermle stellt das zentrale Überwachungstool *HIMS* (B) [6] vor, mit dem Maschinendaten erfasst und ausgewertet werden, sodass eine Übersicht des Live-Status der einzelnen Maschinen abgebildet werden kann. Sobald Auffälligkeiten oder Fehler erkannt werden, wird der zuständige Mitarbeiter benachrichtigt. Das




Bild 1. Qualitative Einordnung von Industrielösungen bezüglich einer intelligenten Prozessüberwachung für die flexible Produktion der Zukunft




Bild 2. Von starren Modellen zur Vision der intelligenten und flexiblen Prozessüberwachung: Einordnung der betrachteten Lösungen bezüglich der Abbildungskomplexität, welche sich aus dem zeitlichen Auflösungsgrad, der Robustheit und der Anpassungsfähigkeit zusammensetzt, und der Dateneffizienz

Überwachungsmodell ist insgesamt jedoch wenig anpassungsfähig und wenig robust, da nur wenige Daten und Parameter betrachtet werden. Diese können dafür bereits mit einem hohen zeitlichen Auflösungsgrad überwacht werden. Da das Modell auf eine Maschine und deren Prozesse zugeschnitten ist, können die Daten im Vergleich zu anderen vorgestellten Technologien effizient genutzt werden, sodass bereits mit wenigen Daten der Live-Status der Maschinen überwacht werden kann.

Im Gegensatz zu *Chiron* und *Hermle* präsentiert *DMG Mori* ein breites Spektrum an Technologien zur Überwachung von Prozessen, die auch unabhängig voneinander eingesetzt werden können. Infolgedessen erfolgt in diesem Beitrag eine separate Bewertung und Einordnung dieser Technologien. Ähnlich zu den bisher vorgestellten Technologien zur Maschinenparküberwachung (C) bietet auch *DMG Mori* einen Laufzeitmonitor [7, 8], um Bearbeitungszyklen zu überwachen und somit Taktzeiten zu optimieren, sowie eine digitale Maschinendatenerfassung [9], mit der eine übersichtliche Leistungsüberwachung des gesamten Maschinenparks möglich ist. Diese Technologien zur Maschinenparküberwachung sind auf konkrete Prozesse und Maschinen zugeschnitten, sodass nur eine geringe Anpassungsfähigkeit an veränderte Be-

dingungen sowie eine geringe Robustheit bezüglich veränderter Daten gegeben ist.

DMG Mori bietet verschiedene Technologien zur Maschinen- und Prozessüberwachung an. Mit *MPC 2.0 - Machine Protection Control* [10, 11] werden während des Prozesses Vibrationen und Drehmomente überwacht, um im Falle eines Crashes eine Schnellabschaltung zu ermöglichen und Schäden zu vermeiden. Auch *MVC - Machine Vibration Control* (D) [12, 13] erfasst mit Hilfe von Schwingungssensoren in der Frässpindel Vibrationen in der Maschine. Sind die Vibrationen zu stark, werden Bearbeitungsvorschläge gemacht, sodass Vibrationen verringert oder vermieden werden. Eine Editierfunktion ermöglicht die Anpassung von Bearbeitungszuständen, wodurch die Prozesssicherheit kontinuierlich beobachtet wird. Dadurch ist eine Anpassung an leicht veränderte Prozessbedingungen möglich.

Um die Werkzeuge und deren Spannkraft zu überwachen, bietet *DMG Mori* folgende Möglichkeiten: *iJAW* (E) [14, 15] überwacht die Spannkraft der Werkzeuge im Prozess mithilfe von Sensoren in einem Kraftspannfutter, um eine kontrollierte Spannkraft während des Zerspanens zu gewährleisten. Durch die Sensoren können auch leicht veränderte Prozessbedingungen überwacht werden und leichte Datenabweichungen verar-

beitet werden. Das *TCC - Tool Control Center* (F) [16, 17] bietet Spannerkennung bei Plan- und Kegelaufnahme und überwacht die Einzugskraft. Durch die Symmetrieüberwachung des Biegemoments können Schneidbrüche erkannt werden. Neben diesen können auch radiale und axiale Spindelbelastungen in Relation zur Werkzeugeinzugskraft visualisiert werden, um Maschine und Werkzeug zu schützen und den Werkzeugeinsatz zu optimieren. Hierbei wird ein hoher zeitlicher Auflösungsgrad realisiert, wobei hier konkrete Daten für eine gute Vorhersage benötigt werden und für veränderte Prozessbedingungen keine aussagekräftigen Vorhersagen getroffen werden können. Im Gegensatz zu den bisher genannten Technologien zur Werkzeugüberwachung funktioniert der *Easy Tool Monitor 2.0* (G) [18, 19] sensorlos mit automatisiertem Lernen von Lastgrenzen für jedes verwendete Werkzeug im Programm. Dadurch lassen sich Schäden im Falle eines Werkzeugbruchs oder einer Werkzeugüberlastung vermeiden. Durch das automatisierte Lernen ist im Vergleich zu den anderen Technologien eine hohe Robustheit sowie eine gute Anpassungsfähigkeit gegeben, wobei gleichzeitig eine geringe Dateneffizienz gegeben ist.

Die Komplexität der Prozesse einer spannenden Fertigung ist hoch, infolgedessen stellt deren Überwachung eine besondere Herausforderung dar. Geeignete Ansätze, welche an das sich ständig ändernde Produktspektrum angepasst sind, existieren bisher nur bedingt. Die in Bild 2 dargestellte Einordnung der bewerteten Überwachungstechnologien erfolgt anhand der Kriterien Dateneffizienz sowie der Abbildungskomplexität, welche sich aus dem zeitlichen Auflösungsgrad, der Robustheit und der Anpassungsfähigkeit zusammensetzt. Das Angebot an Lösungen ist geprägt durch zwei wesentliche Merkmale: eine hohe Abbildungskomplexität oder eine hohe Dateneffizienz. Dies führt dazu, dass Unternehmen tendenziell starre Prozessüberwachungssysteme anbieten, welche auf einen bestimmten Prozess zugeschnitten sind.

In einem flexiblen Produktionsumfeld mit sich ständig ändernden Produktportfolios können solche Überwachungssysteme jedoch an ihre Grenzen stoßen. Modelle müssen mit weniger Daten kontinuierlich

an neue Gegebenheiten angepasst werden. Für eine effiziente Prozessüberwachung sind intelligente Modelle mit hoher Abbildungskomplexität bei gleichzeitig hoher Dateneffizienz notwendig. Nur so können sich Überwachungssysteme schnell an Produktionsbedingungen anpassen. Um effizientere Lösungen zu identifizieren, werden aktuelle Forschungsansätze mit Fokus auf eine höhere Flexibilität und Anpassungsfähigkeit untersucht.

Forschungsansätze zur Erhöhung der Flexibilität von Prozessüberwachungssystemen

Durch die steigende Anzahl an Produktvarianten und die daraus resultierenden Anforderungen an die Produktionsflexibilität haben sich die Anforderungen an traditionelle Prozessüberwachungssysteme im Kontext von Industrie 4.0 grundlegend verändert [20–22]. Die klassischen Systeme basieren auf empirisch festgelegten Grenzwerten und sind standardmäßig reaktiv ausgelegt. Zwar können sie schwerwiegende Fehler wie Werkzeugbruch oder Maschinenausfälle schnell erkennen und dadurch weitere Schäden verhindern, sind jedoch nicht in der Lage, prozessrelevante Fehler frühzeitig zu identifizieren und den Maschinenbediener rechtzeitig zu warnen. Das frühzeitige Erkennen von Fehlern mit kurzer Reaktionszeit ist jedoch entscheidend für eine qualitätsorientierte und ausschussminimierte Produktion. Besonders bei Bauteilen mit langer Produktionszeit kann das rechtzeitige Erkennen von Fehlern die Wirtschaftlichkeit erheblich steigern. Folglich wurden bereits statistisch basierte Methoden untersucht, um potenzielle Anomalien frühzeitig zu identifizieren [23]. Diese Methoden haben sich in der Großserienfertigung mit wiederkehrenden Prozessmustern bereits bewährt. Mit zunehmender Verfügbarkeit von Prozessdaten können Maschinenbediener Eingriffsgrenzen präzisieren. Zusätzlich ermöglichen verschiedene Sensoren, Anomalien unterschiedlicher Art zu erkennen. Der Trend zeigt, dass die Forschung den Fokus auf spezifische Probleme gesetzt hat. Beispielsweise können mithilfe von Schall- und Vibrationsignalen Oberflächenanomalien [24] oder Werkzeugverschleiß [25, 26] bei der spanenden Fertigung identifiziert wer-

den. Auch der Verlauf von Prozesskräften ermöglicht eine Bewertung des Werkzeugzustandes [27].

Anhand der Spindelstromsignale konnten Korrelationen zu den Prozesskräften festgestellt werden [28, 29]. Die besonders einfache Zugänglichkeit der Spindelstromsignale ermöglicht eine kostengünstige Implementierung in Überwachungssysteme. Veränderungen dieser Stromsignale über längere Zeiträume können zudem auf Werkzeugverschleiß hinweisen [28]. Auch durch Beobachtung von kurzfristigen Veränderungen in den Stromsignalen sind Rückschlüsse auf die Prozessqualität möglich [30]. Durch die Einführung von ML-Methoden können noch komplexere Fertigungsprozesse überwacht werden [31]. Zum Beispiel können mittels ML-basiertem Clustering wiederkehrende Prozessschritte identifiziert und deren spezifischer Stromverlauf als Referenzmuster für die Überwachung neuer Produkte verwendet werden [32, 33].

Sowohl statistische als auch modellbasierte Verfahren haben jedoch eine gemeinsame Schwäche: Die Qualität der Vorhersagen hängt entscheidend von den verwendeten Trainingsdaten ab [34]. Insbesondere durch die zunehmende Individualisierung stellt die Datenmenge im Produktionsumfeld eine große Herausforderung dar. Bei der Umstellung auf neue Produktvarianten kann die Gültigkeit eines Modells nicht mehr gewährleistet werden. Dies führt in der Praxis zu Fehlalarmen, die im schlimmsten Fall zu Maschinenstillständen führen.

Ansatz zur Sicherung der Modellvalidität in flexiblen Produktionsumgebungen

Um die Vorhersagequalität bei schwankenden Stückzahlen und hoher Variantenvielfalt zu gewährleisten, müssen Prozessüberwachungssysteme flexibler werden. Ein modellbasiertes System eignet sich besonders für die dynamische Anpassung an den aktuellen Fertigungsprozess. Die Leistungsfähigkeit des Überwachungsmodells, welches den Vergleichswert liefert, bleibt jedoch durch den Mangel an verfügbaren Felddaten für das Training begrenzt. Die Fertigung eines neuen Werkstücks wirkt sich unmittelbar auf die Aussagekraft eines initial trainierten Mo-

dells aus. Weicht der aktuelle Prozess der Generation G_n aufgrund veränderter Randbedingungen von dem im Trainingsdatensatz abgebildeten Originalkontext ab, kommt es zu einem „Domain Shifting“ [35]. Ein klassisch trainiertes Modell kann jedoch nur in bereits bekannten Bereichen zuverlässige Vorhersagen treffen [34]. Um dieses Problem effektiv zu lösen, kann domäneninkrementelles Lernen eingesetzt werden [35]. Ein effektiver Ansatz zur Anpassung des Modells an die neuen Bedingungen ist durch PIML gegeben [36]. Zusätzlich kann AL mit integrierter Daten-Augmentierung dabei helfen, die Modellqualität weiter zu verbessern [37]. Das Wechselspiel der Systemkomponenten ist in Bild 3 dargestellt.

Subsystem 1 – Überwachungsmodell

Die Flexibilität eines Überwachungssystems beginnt bei der Referenzwertbildung. Diese sollte möglichst flexibel in Bezug auf Werkzeugbahn und Bearbeitungsparameter sein und Referenzwerte mit beliebiger zeitlicher Auflösung generieren können. Dies kann durch eine modellbasierte Überwachung erreicht werden. Für die Überwachung von CNC-Fräsmaschinen kann hierfür beispielsweise ein Modell [38] zur Prädiktion der achsspezifischen Stromsignale abgeleitet werden. Durch die Kopplung einer physikalischen Systembeschreibung und einer ML-basierten Abbildung des Stromwertes kann die Dateneffizienz klassischer Ansätze mit der Abbildungskomplexität datenbasierter Ansätze kombiniert werden. Mit Hilfe von Eingangsdaten, die aus der Maschinensteuerung ausgelesen werden, kann dieses hybride Modell zur Generierung von Echtzeit-Sollstromwerten verwendet werden. Als Eingangsgrößen werden Beschleunigung, Geschwindigkeit, Kraft und die MRR (engl. Material Removal Rate) verwendet. Je nach Verfügbarkeit von Sensoren können die Kräfte optional mit einem Softsensor berechnet werden. Hierdurch kann das System auch für Brownfield-Maschinen angewendet werden. Die Daten der MRR werden durch eine integrierte voxelbasierte Abtragsimulation ermittelt. Durch die Integration einer Anomalieerkennung können die gemessenen Achsströme mit den berechneten Werten verglichen werden. Prozessanomalien werden zur Erhöhung der




Bild 3. Konzept des modellbasierten Prozessüberwachungssystems für die flexible Fertigung. Es setzt sich aus den Subsystemen Überwachungsmodell, PIML sowie AL mit integrierter Daten-Augmentierung zusammen, welche durch das Domänen-inkrementelle Lernen produktübergreifend zusammenspielen

Robustheit in Intervallen zusammengefasst, welche ab einer relevanten Größe angezeigt und gespeichert werden können. Zur Identifikation dieser Anomalieintervalle kann je nach Bedarf eine unterschiedliche Strategie gewählt werden.

Subsystem 2 – PIML

Aufgrund der hybriden Modellstruktur [38] ist neben dem Gesamtmodell auch die Beschreibung der physikalischen Gleichungen gegeben. Diese ist zwar in der Abbildungskomplexität gegenüber einer ML-basierten Abbildung eingeschränkt, aufgrund der physikalischen Zusammenhänge jedoch in der Lage, physikalisch plausibel zu extrapolieren. Folglich kann dies bei einem neuen Prozess genutzt werden, um bis zum Vorliegen realer Daten nach der Produktion Stützstellen zu generieren. Diese ermöglichen eine verbesserte Extrapolation und können somit die Prognosegüte des Gesamtmodells in bisher unbekannten Prozessen deutlich verbessern.

Vor Beginn des Fertigungsprozesses werden hierfür die Betriebsbedingungen der Maschine analysiert und fehlende Prozessbereiche im vorhandenen Trainingsdatensatz identifiziert. Auf Basis des NC-Codes werden die Eingangsparameter generiert und die Stromwerte mittels der

physikalischen Gleichung erzeugt. Um die fehlenden Bereiche im Merkmalsraum zu vervollständigen, ergänzen die generierten Datenpunkte den bisherigen Trainingsdatensatz. Diese gezielte Anpassung des Trainingsdatensatzes stellt eine integrierte und kontinuierliche Anpassungsschleife im Fertigungsprozess dar. Durch diese zirkuläre Strategie wird das Prozessüberwachungsmodell stets für die aktuelle Werkstückgenerationen G_n angepasst, wodurch einer reduzierten Datenmenge bei einem Produktwechsel effektiv begegnet werden kann.

Subsystem 3 – AL mit integrierter Daten-Augmentierung

Treten während des Prozesses Abweichungen zwischen dem realen und dem vorhergesagten Signal auf, werden diese in der klassischen Prozessüberwachung rein als Prozessabweichung betrachtet. Insbesondere in einem komplexen Produktionsumfeld ist jedoch davon auszugehen, dass Anomalien auch auf eine schlechte Vorhersagegüte zurückzuführen sind. Hier können AL-Ansätze helfen, das Überwachungsmodell zu verbessern und die Fehlalarme zukünftig zu vermeiden. Hierfür werden die während des Produktionsprozesses identifizierten Intervalle analysiert. Liegt ein Alarm vor,

beurteilt eine Fachkraft, ob es sich bei dem Intervall um einen tatsächlichen Prozessfehler handelt. Ist dies nicht der Fall, wurde die Abweichung durch datenbasierte Modellfehler verursacht und es erfolgt eine Annotation der Intervalldaten. Diese Information steht nun für ein Modelltraining zur Verfügung.

Aus Sicht des Überwachungssystems sind insbesondere datenbasierte Modellfehler unerwünscht, da sie einen Fehlalarm auslösen können. AL bietet die Möglichkeit, den Trainingsdatensatz in solchen Bereichen gezielt zu erweitern. Um die Genauigkeit des Modells in diesen Bereichen zu verbessern, werden diese in den Trainingsdatensatz für das nächste Werkstück aufgenommen. Das Hinzufügen ähnlicher, aber nicht identischer Datenpunkte kann zu einer weiteren Erhöhung der Robustheit und Generalisierbarkeit führen [37, 39]. Eine Daten-Augmentierung bietet somit eine Möglichkeit, die Vorhersagegenauigkeit des Modells weiter zu verbessern.

Somit bietet dieses Subsystem einen Ansatz, das Modell auch bei schlechter Prognosegüte, abgesichert durch das Votum einer Fachkraft, kontinuierlich zu verbessern und weiterzuentwickeln. Dadurch kann sich das Überwachungssystem kontinuierlich an die realen Produktionsbedingungen anpassen, ohne dass vorher gezielt Daten durch eine vorherige Fertigung aufgenommen werden müssen.

Domäneninkrementelles Lernen

Der fortlaufende Produktgenerationswechsel führt zu neuen Prozesszuständen, was für das trainierte Modell eine Veränderung der ursprünglichen Trainingsdomäne bedeutet [35]. Mithilfe des domäneninkrementellen Lernens wird diese Veränderung berücksichtigt. Die Zusammenführung der drei Subsysteme ergibt das in Bild 3 dargestellte Gesamtsystem. Nach jedem Produktionsprozess steht ein aktualisierter und balancierter Trainingsdatensatz zur Verfügung. Das Training erfolgt immer vor der Produktion der neuen Generation, wobei der neu zusammengestellte und optimierte Trainingsdatensatz verwendet wird. Im Produktionsprozess eines Werkstücks der Generation G_n stehen die Daten aller Vorgängergenerationen zur Verfügung. Durch den fortlaufenden Produktgenera-

tionswechsel entstehen zunehmend mehr Daten, die je nach Bedarf dem Trainingsdatensatz hinzugefügt werden. Die physikbasierte Datenergänzung nutzt den NC-Code des aktuellen Bauteils als Grundlage, um fehlende Bereiche im Merkmalsraum durch synthetische Datenpunkte zu ergänzen. Auf Basis dieses erweiterten Datensatzes wird das Überwachungsmodell für die Produktion neuer Bauteile trainiert und optimiert. Während des Produktionsprozesses werden Intervalle mit Auffälligkeiten identifiziert und als Warnung ausgegeben. Nach dem Produktionsprozess haben Fachkräfte die Möglichkeit, die identifizierten Intervalle im Detail zu analysieren. Die Daten der Intervalle, die nicht auf Prozessfehler zurückzuführen sind, werden mittels Augmentierung erweitert, um eine möglichst hohe Robustheit und Generalisierbarkeit zu gewährleisten.

In einer laufenden Produktion mit mehreren Generationswechseln wird durch den Systemaufbau ein kontinuierlicher Trainingszyklus realisiert, der eine möglichst schnelle und dateneffiziente Anpassung des Überwachungssystems an neue Bedingungen ermöglicht. Die Trainingsdatensätze werden jeweils vor dem Fertigungsprozess an das neue Bauteil angepasst und optimiert. Zusätzlich werden die Trainingsdatensätze nach dem Fertigungsprozess durch AL erweitert, um die Qualität des Modells stetig zu verbessern.

Diskussion und Fazit

Es sind bereits einige Lösungen zur Prozessüberwachung erhältlich, welche jedoch oft starr und auf einzelne Prozesse oder Prozessschritte zugeschnitten sind. Solche Systeme haben sich bereits in der Massenfertigung und bei Produktspektren mit wiederkehrenden Bearbeitungsmustern bewährt. Unternehmen wie *DMG Mori*, *Hermle* und *Chiron* bieten beispielsweise bereits Monitoring-Systeme zur Überwachung einzelner Prozessparameter an. Jedoch sind diese bisher nur bedingt in der Lage, sich flexibel und effizient an veränderte Produktionsbedingungen anzupassen. Der Trend zu immer komplexeren und flexibleren Produktionsprozessen mit immer kürzeren Produktlebenszyklen erfordert je-

doch dynamische und adaptive Überwachungsmodelle.

Um die Flexibilität von Überwachungsmodellen zu erhöhen, wird im vorgestellten Ansatz Wissen durch zwei kombinierte Strategien (PIML und AL) in den Trainingsprozess integriert. Damit ist eine Einordnung in eine Informed-ML-Taxonomie [40] möglich. Die PIML-Strategie basiert auf Wissen und physikalischen Gesetzmäßigkeiten in Form von Systemgleichungen. Bei der AL-Strategie wird zusätzlich Expertenwissen über eine Mensch-Maschine-Schnittstelle in das Trainingssystem integriert. Dadurch wird es möglich, auch ohne große Mengen an Produktionsdaten in einer agilen Produktionsumgebung Überwachungsmodelle flexibel und dateneffizient zu betreiben.

Bei der Anwendung dieses Ansatzes sind jedoch einige wichtige Aspekte zu beachten: Das zugrundeliegende Modell kann nur dann präzise Vorhersagen liefern, wenn qualitativ hochwertige Trainingsdaten vorliegen. Diese hängt stark von der aufgestellten Systemgleichung und der Qualität des Expertenwissens ab. Zudem muss definiert werden, wann eine Abweichung als Anomalie zu betrachten ist. Eine zu hohe Empfindlichkeit kann dazu führen, dass eine große Anzahl von Intervallen bewertet werden muss. Daher ist zwischen einer hohen Sensitivität und der damit verbundenen Sicherheit und dem Bewertungsaufwand abzuwägen.

Insgesamt bietet der vorgestellte Ansatz zur intelligenten Prozessüberwachung durch die Kombination von hybriden Überwachungsmodellen, PIML und AL eine vielversprechende Lösung für die Prozessüberwachung in flexiblen Produktionsumgebungen. Im Vergleich zu bereits existierenden Lösungen berücksichtigt der vorgestellte Ansatz sowohl Expertenwissen als auch physikalische Gesetze. Durch die kontinuierliche Anpassung der Überwachungsmodelle an sich ändernde Bedingungen können Prozessüberwachungssysteme flexibilisiert und damit Fehlalarme reduziert sowie die Vorhersagegenauigkeit erhöht werden. In zukünftigen Arbeiten wird sich mit der Untersuchung der einzelnen Subkomponenten sowie deren Einfluss auf die Flexibilität beschäftigt.

Literatur

1. Koren, Y.: The Global Manufacturing Revolution: Product-process-business Integration and Reconfigurable Systems. John Wiley & Sons. 2010
DOI:10.1002/9780470618813
2. Peichl, A.; Sauer, S.; Wohlrabe, K.: Fachkräftemangel in Deutschland und Europa-Historie, Status quo und was getan werden muss. ifo Schnelldienst, 75(2022) 10, S. 70–75
3. Hadad, Y.; Keren, B.: A Revised Method for Allocating the Optimum Number of Similar Machines to Operators. International Journal of Productivity and Performance Management 65 (2016) 2, S. 223–244
DOI:10.1108/IJPPM-10-2014-0163
4. Statista (Hrsg.): Produktion. Größte Hersteller spanender Werkzeugmaschinen in Europa nach Umsatz im Jahr 2021 (in Millionen Euro). (<https://de.statista.com/statistik/daten/studie/459458/umfrage/groessterhersteller-spanender-werkzeugmaschinen-in-europa-nach-umsatz/>) [Abgerufen am 25.1.2025]
5. CHIRON Group SE: SmartLine – Digitale Systeme für Ihre Fertigung von morgen. (<https://chiron-group.com/de/kompetenzen/digitale-loesungen/smartline>) [Abgerufen am 25.1.2025]
6. Maschinenfabrik Berthold HERMLE AG: Automatisierung – Hermle geht den nächsten Schritt mit HIMS. (<https://www.hermle.de/de/news-media/news/detail/automatisierung-hermle-geht-den-naechsten-schritt-mit-hims/>) [Abgerufen am 25.1.2025]
7. DMG MORI AG: 63 exklusive DMG MORI Technologiezyklen – Komplexe Bearbeitung einfach realisiert. S. 56–57 (<https://de.dmgmori.com/produkte/digitalisierung/technologiezyklen/drehen-und-dreh-fraesen/ueberwachen/laufzeitmonitor>) [Abgerufen am 25.1.2025]
8. DMG MORI AG: Laufzeitmonitor. (<https://de.dmgmori.com/produkte/digitalisierung/technologiezyklen/drehen-und-dreh-fraesen/ueberwachen/laufzeitmonitor>) [Abgerufen am 25.1.2025]
9. DMG MORI AG: Digitale Maschinendatenerfassung (MDE). (<https://de.dmgmori.com/produkte/digitalisierung/tulip/anwendungsbeispiele/digitale-maschinendatenerfassung>) [Abgerufen am 25.1.2025]
10. DMG MORI AG: 63 exklusive DMG MORI Technologiezyklen – Komplexe Bearbeitung einfach realisiert. S. 96–97 (<https://de.dmgmori.com/produkte/digitalisierung/technologiezyklen/drehen-fraesen/ueberwachen/mpc>) [abgerufen am 25.1.2025]
11. DMG MORI AG: MPC 2.0 – Machine Protection Control. (<https://de.dmgmori.com/produkte/>)

- digitalisierung/technologiezyklen/drehen-fraesen/ueberwachen/mpc [Abgerufen am 25.1.2025])
12. DMG MORI AG: 63 exklusive DMG MORI Technologiezyklen – Komplexe Bearbeitung einfach realisiert. S. 120–121 (<https://de.dmgmori.com/produkte/digitalisierung/technologiezyklen/drehen-fraesen/ueberwachen/mvc>) [Abgerufen am 25.1.2025])
 13. [13] DMG MORI AG: MVC – Machine Vibration Control. (<https://de.dmgmori.com/produkte/digitalisierung/technologiezyklen/fraesen-und-fraes-drehen/ueberwachen/mvc>) [Abgerufen am 25.1.2025])
 14. DMG MORI AG: 63 exklusive DMG MORI Technologiezyklen – Komplexe Bearbeitung einfach realisiert. S. 58–59 (<https://de.dmgmori.com/produkte/digitalisierung/technologiezyklen/drehen-und-dreh-fraesen/ueberwachen/ijaw>) [Abgerufen am 25.1.2025])
 15. DMG MORI AG: iJAW – Smarter spannen! (<https://de.dmgmori.com/produkte/digitalisierung/technologiezyklen/drehen-und-dreh-fraesen/ueberwachen/ijaw>) [Abgerufen am 25.1.2025])
 16. DMG MORI AG: 63 exklusive DMG MORI Technologiezyklen – Komplexe Bearbeitung einfach realisiert. S. 122–123 (<https://de.dmgmori.com/produkte/digitalisierung/technologiezyklen/fraesen-und-fraes-drehen/ueberwachen/tcc>) [Abgerufen am 25.1.2025])
 17. DMG MORI AG: TCC – Tool Control Center. (<https://de.dmgmori.com/produkte/digitalisierung/technologiezyklen/fraesen-und-fraes-drehen/ueberwachen/tcc>) [Abgerufen am 25.1.2025])
 18. DMG MORI AG: 63 exklusive DMG MORI Technologiezyklen – Komplexe Bearbeitung einfach realisiert. S. 94–95 (<https://ch-de.dmgmori.com/produkte/digitalisierung/technologiezyklen/drehen-fraesen/ueberwachen/easy-tool-monitoring>) [Abgerufen am 25.1.2025])
 19. DMG MORI AG: Easy Tool Monitor 2.0. (<https://ch-de.dmgmori.com/produkte/digitalisierung/technologiezyklen/drehen-fraesen/ueberwachen/easy-tool-monitoring>) [Abgerufen am 25.1.2025])
 20. Ahmad, M. I.; Yusof, Y.; Daud, M. et al.: Machine Monitoring System: a Decade in Review. *International Journal of Advanced Manufacturing Technology* 108 (2020) 11–12, S. 3645–3659
DOI:10.1007/s00170-020-05620-3
 21. Denkena, B.; Dahlmann, D.; Shanib, M. et al.: Prozessüberwachung in der Zerspanung. *Zeitschrift für wirtschaftlichen Fabrikbetrieb ZWF* 111 (2016) 4, S. 174–177
DOI:10.3139/104.111495
 22. Abellan-Nebot, J. V.; Romero Subirón, F.: A Review of Machining Monitoring Systems Based on Artificial Intelligence Process Models. *International Journal of Advanced Manufacturing Technology* 47 (2010) 1–4, S. 237–257
DOI:10.1007/s00170-009-2191-8
 23. Brinkhaus, J.-W.: Statistische Verfahren zur selbstlernenden Überwachung spanender Bearbeitungen in Werkzeugmaschinen. In: *Berichte aus dem IFW/Institut für Fertigungstechnik und Werkzeugmaschinen*, Bd. 05/2009, 126 S.
 24. Axinte, D. A.; Gindy, N.; Fox, K.; Unanue, I.: Process Monitoring to Assist the Workpiece Surface Quality in Machining. *International Journal of Machine Tools and Manufacture* 44 (2004) 10, S. 1091–1108
DOI:10.1016/j.ijmachtools.2004.02.020
 25. Huang, Z.; Zhu, J.; Lei, J. et al.: Tool Wear Monitoring with Vibration Signals Based on Short-Time Fourier Transform and Deep Convolutional Neural Network in Milling. *Mathematical Problems in Engineering* (2021), S. 1–14
DOI:10.1155/2021/9976939
 26. Twardowski, P. T.; Tabaszewski, M.; Wiciak-Pikuła, M.; Felusiak-Czyryca, A.: Identification of Tool Wear Using Acoustic Emission Signal and Machine Learning Methods. *Precision Engineering* 72 (2021), S. 738–744
DOI:10.1016/j.precisioneng.2021.07.019
 27. Dimla, D. E.; Lister, P. M.: Online Metal Cutting Tool Condition Monitoring. *International Journal of Machine Tools and Manufacture* 40 (2000) 5, S. 739–768
DOI:10.1016/S0890-6955(99)00084-X
 28. Ammouri, A. H.; Hamade, R. F.: Current Rise Criterion: a Process-independent Method for Tool-condition Monitoring and Prognostics. *International Journal of Advanced Manufacturing Technology* 72 (2014) 1–4, S. 509–519
DOI:10.1007/s00170-014-5679-9
 29. Li, X.; Djordjevic, A.; Venuvinod, P. K.: Current-sensor-based Feed Cutting Force Intelligent Estimation and Tool Wear Condition Monitoring. *IEEE Transactions on Industrial Electronics* 47 (2000) 3, S. 697–702
DOI:10.1109/41.847910
 30. Xi, T.; Benincá, I. M.; Kehne, S. et al.: Tool Wear Monitoring in Roughing and Finishing Processes Based on Machine Internal Data. *International Journal of Advanced Manufacturing Technology* 113 (2021) 11–12, S. 3543–3554
DOI:10.1007/s00170-021-06748-6
 31. Surucu, O.; Gadsden, S. A.; Yawney, J.: Condition Monitoring Using Machine Learning: A Review of Theory, Applications, and Recent Advances. *Expert Systems with Applications* 221 (2023)
DOI:10.1016/j.eswa.2023.119738
 32. Netzer, M.; Michelberger, J.; Fleischer, J.: Intelligent Anomaly Detection of Machine Tools Based on Mean Shift Clustering. *Procedia CIRP* 93 (2020), S. 1448–1453
DOI:10.1016/j.procir.2020.03.043
 33. Netzer, M.: Intelligente Anomalieerkennung für hochflexible Produktionsmaschinen: Prozessüberwachung in der Brownfield Produktion. *Shaker Verlag, Düren* 2023
 34. Wu, Y.; Sicard, B.; Gadsden, S. A.: Physics-informed Machine Learning: A Comprehensive Review on Applications in Anomaly Detection and Condition Monitoring. *Expert Systems with Applications* 255 (2024)
DOI:10.1016/j.eswa.2024.124678
 35. Ven, G. M. van de; Tuytelaars, T.; Tolias, A. S.: Three Types of Incremental Learning. *Nature Machine Intelligence* 4 (2022) 12, S. 1185–1197
DOI:10.1038/s42256-022-00568-3
 36. Karniadakis, G. E.; Kevrekidis, I. G.; Lu, L. et al.: Physics-informed Machine Learning. *Nature Reviews Physics* 3 (2021) 6, S. 422–440
DOI:10.1038/s42254-021-00314-5
 37. Moreno-Barea, F. J.; Jerez, J. M.; Franco, L.: Improving Classification Accuracy Using Data Augmentation on Small Data Sets. *Expert Systems with Applications* 161 (2020)
DOI:10.1016/j.eswa.2020.113696
 38. Ströbel, R.; Mau, M.; Puchta, A.; Fleischer, J.: Improving Time Series Regression Model Accuracy via Systematic Training Dataset Augmentation and Sampling. *MAKE* 6 (2024) 2, S. 1072–1086
DOI:10.3390/make6020049
 39. Hernández-García, A.; König, P.: Data Augmentation Instead of Explicit Regularization. 2018
DOI:10.48550/ARXIV.1806.03852
 40. Rueden, L. von; Mayer, S.; Beckh, K. et al.: Informed Machine Learning – A Taxonomy and Survey of Integrating Prior Knowledge into Learning Systems. *Transactions on Knowledge and Data Engineering, IEEE* 2021
DOI:10.1109/TKDE.2021.3079836

Die Autor:innen dieses Beitrags

Robin Ströbel, M. Sc., promoviert als wissenschaftlicher Mitarbeiter am Institut für Produktionstechnik (wbk) des Karlsruher Instituts für Technologie (KIT) in dem Fachgebiet Intelligenter Maschinen und Komponenten. Seine Forschung konzentriert sich auf die dateneffiziente Modellierung von Maschinenverhalten im Produktionsumfeld.

Hafez Kader, M. Sc., promoviert als wissenschaftlicher Mitarbeiter in der Arbeitsgruppe für Autonome Multisensor-Systeme (AMS) an der Fakultät für Informatik der Otto-von-Guericke-Universität Magdeburg (OVGU). In seiner Forschung konzentriert er sich im Bereich Data Science auf die Analyse der Relevanz und Bedeutung verschiedener Features sowie auf die Erkennung von Anomalien in Sensordaten, um Prozesse effizienter zu gestalten und die

Performance von Machine-Learning-Modellen zu optimieren.

Louisa Hutt, B. Sc., studiert Wirtschaftsingenieurswesen am Karlsruher Institut für Technologie (KIT).

Hanlin Zhou, B. Sc., studiert Maschinenbau am Karlsruher Institut für Technologie (KIT).

Marcus Mau, M. Sc., promoviert als wissenschaftlicher Mitarbeiter am Institut für Produktionstechnik (wbk) am Karlsruher Institut für Technologie (KIT) in dem Fachgebiet Intelligente Maschinen und Komponenten. Seine Forschung konzentriert sich auf die zustandsadaptive Modellbildung von Werkzeugmaschinen.

Alexander Puchta, M. Sc., ist Oberingenieur am Institut für Produktionstechnik (wbk) am Karlsruher Institut für Technologie (KIT) in dem Fachgebiet Intelligente Maschinen und Komponenten.

Prof. Dr.-Ing. Benjamin Noack studierte Informatik an der Universität Karlsruhe (TH) und promovierte 2013 am Lehrstuhl für Intelligente Sensor-Aktor-Systeme (ISAS). Seit 2021 ist er Professor an der Fakultät für Informatik der Otto-von-Guericke-Universität Magdeburg (OVGU) und leitet dort die Arbeitsgruppe für Autonome Multisensor-Systeme (AMS). In der Forschung beschäftigt er sich mit verteilter Sensordatenfusion und deren Anwendungen im Bereich der industriellen Prozessüberwachung sowie autonomen mobilen Robotik.

Prof. Dr.-Ing. Jürgen Fleischer studierte Maschinenbau an der Universität Karlsruhe (TH)

und promovierte 1989 am Institut für Werkzeugmaschinen und Betriebstechnik (wbk). Von 1992 an war er in mehreren leitenden Positionen in der Industrie tätig, ehe er im Jahr 2003 zum Professor und Leiter des wbk Institut für Produktionstechnik am heutigen Karlsruher Institut für Technologie (KIT) berufen wurde. Seine aktuellen wissenschaftlichen Forschungsschwerpunkte umfassen intelligente Maschinen und Komponenten, die Automatisierung unreifer Prozesse sowie agile Produktionsanlagen.

Abstract

Intelligent Process Monitoring for Flexible Manufacturing – Integrating Physics-Informed Machine Learning and Active Learning. As products and their production become more personalized and variant rich, traditional approaches to process monitoring are reaching their limits. These are typically based on static data sets or recurring process patterns, which can lead to inaccurate predictions and increased false alarms in agile production environments. This article presents a concept for flexibilising the process monitoring of discrete production processes based on the combination of Physics-informed Machine Learning (PIML) and Active Learning (AL). In agile production environments, this allows not only the detection of anomalies, but also the automatic update of the monitoring model in case of false alarms. As a result, the monitoring system remains accurate under

variable production conditions, reducing the number of false alarms and contributing to improved Overall Equipment Effectiveness (OEE).

Förderhinweis

Gefördert durch das Bundesministerium für Wirtschaft und Klimaschutz aufgrund eines Beschlusses des Deutschen Bundestages durch die Gesellschaft zur Förderung angewandter Informatik e. V. – GfAI (IGF-Vorhaben Nr.: 22849 BG/2).

Schlüsselwörter

Prozessüberwachung, Flexible Produktion, Anomalieerkennung, Active Learning, Physics-Informed Machine Learning

Keywords

Process Monitoring, Flexible Production, Anomaly Detection, Active Learning, Physics-informed Machine Learning

Bibliography

DOI 10.1515/zwf-2024-0154

ZWF 120 (2025) Special Issue; page 224 – 231

Open Access. © 2025 bei den Autoren,

publiziert von De Gruyter. 

Dieses Werk ist lizenziert unter der Creative Commons Namensnennung 4.0 International Lizenz.

ISSN 0947-0085 · e-ISSN 2511-0896