

Berücksichtigung von Unsicherheiten in der Zerspanung

Adaptive Prüfplanung

B. Denkena, M. Wichmann, L. Reuter

ZUSAMMENFASSUNG Datengetriebene Prognosemodelle sind der Kern einer adaptiven Prüfplanung, besitzen jedoch stets einen modellbasierten Prognosefehler. Zur zuverlässigen Interpretation des Vorhersageergebnisses ist daher die Modellierung der einhergehenden Unsicherheit von besonderer Bedeutung. In diesem Beitrag werden drei Ansätze zur Unsicherheitsmodellierung der Oberflächenrauheit 3-achsig gefräster Werkstücke aus Aluminium vorgestellt, wobei eine hohe Erfassungswahrscheinlichkeit von 92 % erzielt werden kann.

STICHWÖRTER

CAQ, Qualitätsmanagement, Qualitätssicherung

Adaptive inspection planning – Consideration of uncertainties in machining

ABSTRACT Data-driven prediction models are the core of adaptive test planning, but always have a model-based prediction error. For a reliable interpretation of the prediction result, the modeling of the associated uncertainty is of particular importance. Therefore, this paper presents an approach for uncertainty modeling of the surface roughness Ra of 3-axis milled aluminum workpieces, whereby a Prediction Interval Coverage Probability of 92% can be achieved.

1 Einleitung

In der Luftfahrtindustrie herrschen hohe Anforderungen an die Herstellung zerspanter Bauteile. Insbesondere die vollständige Qualitätsprüfung von Großbauteilen (zum Beispiel Flugzeugspannte) auf Einhaltung von Geometrie- oder Rauheitsvorgaben ist zeit- und kostenintensiv. Datenbasierte Vorgehensweisen innerhalb der Prüfplanung besitzen daher ein besonderes Potenzial zur Steigerung der Wettbewerbsfähigkeit [1]. Ein Ansatz zur Identifikation und Reduzierung vermeidbarer Prüfaufwände in der Zerspanung stellt die adaptive Prüfplanung dar [2]. Hierbei erfolgt die wirtschaftliche Planung von konventionellen Qualitätsprüfungen durch die Interpretation datengetriebener Qualitätsprognosen auf Basis von Methoden des maschinellen Lernens. Sämtliche Regressionsmodelle besitzen jedoch einen Prognosefehler, der im Rahmen der Modellentwicklung anhand verschiedener Bewertungsmetriken (unter anderem mittlerer absoluter Fehler (MAE) oder mittlerer absoluter prozentualer Fehler (MAPE)) quantifiziert und minimiert wird [3]. Innerhalb sicherheitsrelevanter Branchen erschweren derartige Prognosefehler eine Einführung datenbasierter Vorgehensweisen aufgrund hoher Anforderungen an die Qualifizierung und Zertifizierung von Prüfmethoden [4]. Somit besteht die Notwendigkeit zur Berücksichtigung von Modellunsicherheiten, um das Risiko einer Fehlinterpretation datenbasierter Prognoseergebnisse zu reduzieren. Erste Ansätze hierzu wurden in den letzten Jahren von Kowalczyk und Tomczyk, Lui *et al.* sowie Sun *et al.* entwickelt [5–7].

Kowalczyk und Tomczyk entwickelten eine Methode zur Bestimmung von Unsicherheiten in der Modellierung von Oberflächenrauheiten beim Drehen von NiTi-Legierungen auf Basis eines Monte-Carlo-Ansatzes. Die Modellierung der Rauheit

erfolgte durch die Bildung von Polynomen in Abhängigkeit des Vorschubs v_f , der Schnitttiefe a_p sowie der Spindeldrehzahl n [5]. Zur Modellierung des Werkstückverzugs, beispielsweise durch die Zerspanung dünnwandiger Bauteile, werden häufig rechen- und zeitintensive Finite-Elemente-Analysen durchgeführt, die für industrielle Zwecke nur eingeschränkt nutzbar sind. Sun *et al.* haben daher ein hybrides Ersatzmodell auf Basis der Gaußprozess Regression (GPR) entwickelt, das ebenfalls die Unsicherheit der Verzugsprognose berücksichtigt. Im Rahmen einer Fallstudie konnte ein mittlerer Prognosefehler von 3,14 μm beziehungsweise 11,69 % aufgezeigt werden [6]. Um den Einfluss der Schnittparameter auf die Oberflächenrauheit zu quantifizieren und die Vorhersagegenauigkeit zu verbessern, entwickelten Lui *et al.* eine neuartige Vorgehensweise zur Modellierung der Oberflächenrauheit beim Fräsen. Auf Basis von Überwachungssignalen sowie Prozessstellgrößen erfolgt die Prognose der Rauheit und die Bildung eines Konfidenzintervalls mittels Bayes'schen Quantilmodells. Der verbleibende Vorhersagefehler lag gegenüber experimentellen Versuchen bei etwa 15 % [7].

Die dargestellten Ergebnisse zeigen das Potenzial zur Modellierung von Unsicherheiten, insbesondere im Kontext der spanenden Fertigung. Es existiert eine Vielzahl an stochastischen Einflüssen, welche die Unsicherheit über die zu erwartenden Werkstückqualität beeinflussen [8]. Bisher liegen jedoch keine Ansätze vor, die eine Einbindung der Unsicherheitsmodellierung innerhalb der Prüfplanung untersucht haben. Dies ist allerdings zur Industrialisierung der Vorgehensweise von besonderer Bedeutung. Der vorliegende Beitrag evaluiert daher drei verschiedene Ansätze der Unsicherheitsmodellierung zur Rauheitsprognose von 3-achsig gefrästen Werkstücken aus Aluminium im Rahmen einer adaptiven Prüfplanung.

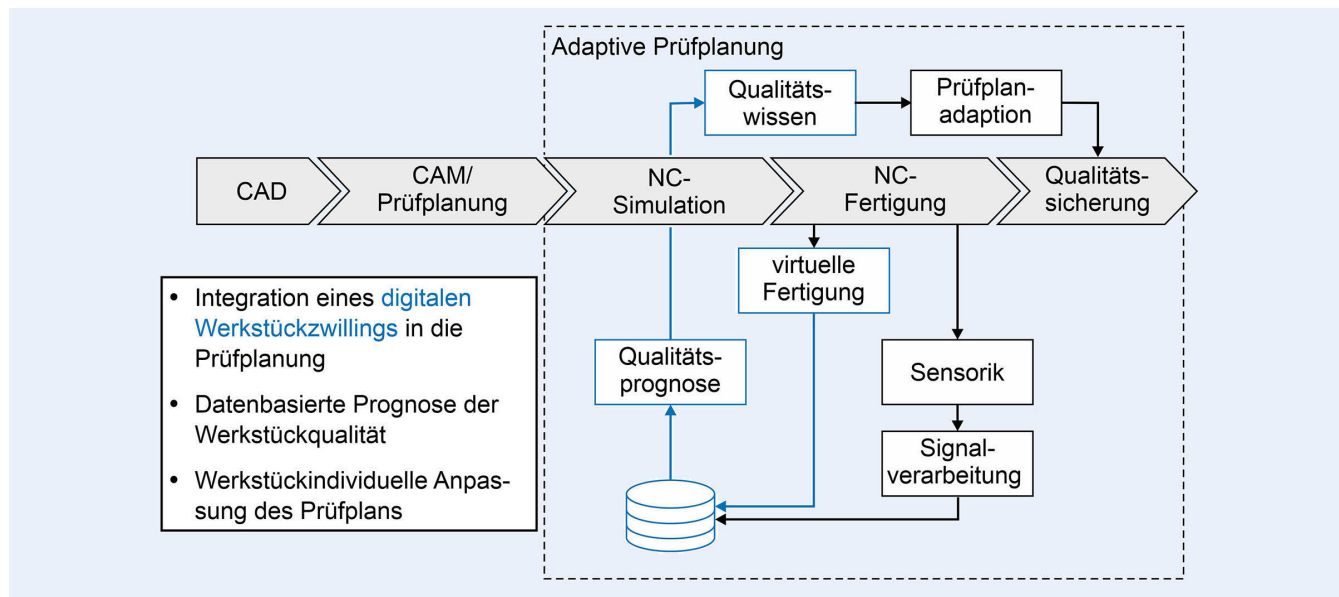


Bild 1. Methode zur adaptiven Prüfplanung. Grafik: IFW

2 Adaptive Prüfplanung

Innerhalb der CAD-CAM-Kette findet die produktabhängige Prüfplanung typischerweise einmalig parallel oder im Anschluss an die CAM-Planung statt. Anschließend liegen sämtliche Schritte der Qualitätsprüfung vor, die für jedes zu prüfende Bauteil durchgeführt werden. Eine individuelle Adaption von Prüfaufwänden wird nicht vorgenommen, besitzt jedoch das Potenzial, Prüf- und Durchlaufzeiten deutlich zu reduzieren. Die adaptive Prüfplanung nutzt hierzu einen digitalen Werkstückzwilling, um vermeidbare Aufwände in der Qualitätssicherung durch eine werkstückindividuelle Anpassung von Prüfaufträgen zu reduzieren [2]. Die Vorgehensweise hierzu ist in **Bild 1** schematisch dargestellt.

Nach der spanenden Bearbeitung des Werkstücks werden zunächst die relevanten Maschinen-, Sensor-, Simulations- und Qualitätsdaten als digitaler Fußabdruck des Werkstücks gespeichert. Die Aufnahme von Qualitätsdaten ist zur Entwicklung virtueller Prüfmethode notwendig. Als virtuelles Prüfmittel sind in diesem Kontext Regressionsmodelle zu verstehen, die eine Korrelation zwischen den Eingangsgrößen aus der Maschine, der Sensorik oder der Simulation mit dem vorliegenden Qualitätsniveau liefern. Derartige Modelle werden in der Simulationsumgebung genutzt, um neues Wissen über die vorliegende Werkstückqualität zu gewinnen, ohne eine konventionelle Qualitätsprüfung durchführen zu müssen. Dieses Wissen besitzt für die weitere Prüfplanung eine entscheidende Bedeutung, da der Prüfplan in Abhängigkeit des virtuellen Prognoseergebnisses adaptiert wird. So erfolgt durch den Vergleich zwischen Soll- und Ist-Qualitätsniveau die Klassifizierung der Prüfmerkmale in die Gruppen „in Ordnung“ und „nicht in Ordnung“. Sofern die virtuelle Qualitätsprognose ein eindeutiges Ergebnis liefert, ist keine weitere Prüfung des Merkmals notwendig und der Prüfplan wird um dieses Merkmal reduziert. Sollte das prognostizierte Prüfergebnis jedoch nah an der Toleranzgrenze liegen, ist die Werkstückqualität konventionell zu messen. In diesem Fall werden die Prüfaufwände nicht reduziert. Somit führt eine Fehleinschätzung des vorliegenden Qualitätsniveaus im Kontext der adaptiven Prüfplanung

unmittelbar zu einem Nichterkennen („Durchschlupf“) von qualitätskritischen Werkstücken und erschwert folglich die Implementierung datenbasierter Methoden. Unter Berücksichtigung der oben beschriebenen Erkenntnisse ist eine Unsicherheitsmodellierung im Zusammenhang der adaptiven Prüfplanung unerlässlich.

3 Ansätze zur Unsicherheitsmodellierung

Insbesondere in der Luftfahrtindustrie herrschen umfangreiche Prüfumfänge zur Sicherstellung einer qualitätsgerechten Fertigung. So sind zeitliche Aufwände von 4,5 h zur Messung von Oberflächenrauheiten und Formabweichungen bei Großbauteilen nicht unüblich. Das Demonstratorbauteil stellt einen Ausschnitt aus einem realen Türspant dar. Das Analogiebauteil enthält dieselben Features und wurde zur Reduzierung von Versuchsdauern und Materialeinsatz entworfen. Exemplarisch erfolgte die Modellierung der Unsicherheiten bei der Prognose der Oberflächenrauheit R_a in diesem Beitrag anhand von drei verschiedenen Ansätzen. Zur Evaluierung wurden 60 Analogiebauteile (170 mm x 115 mm x 80 mm) aus Aluminium (EN AW 5083) mit acht verschiedenen Parameterkonstellationen gefertigt. Die Versuche wurden am Bearbeitungszentrum „H5000“ von Heller mit einer Siemens „840 D sl“ Steuerung durchgeführt (**Bild 2**).

Die notwendigen Maschinendaten (Achspositionen, Spindeldrehzahl n sowie Vorschubgeschwindigkeit v_f) wurden mit einer Frequenz von 160 Hz über eine TCP/IP-Schnittstelle ausgelesen. Des Weiteren haben Voruntersuchungen ergeben, dass das Prozesswissen und damit die Prognosegüte in der Modellierung durch die Nutzung von Simulationsdaten deutlich gesteigert werden kann. Auf Basis der ausgelesenen Achspositionen erfolgte daher anschließend eine dextralbasierte Materialabtragsimulation des Bearbeitungsprozesses zur Berechnung der lokalen Eingriffsbedingungen Zeitspanvolumen Q_w , Schnitttiefe a_p , Schnittbreite a_e sowie Werkzeugeingriffswinkel ϕ in IFW CutS [9]. Hierzu wurde eine Dixelauflösung von 20 Dixel/mm und eine Zykluszeit von 0,001 s genutzt. Prozesskräfte wurden während des Fräsprozesses




Bild 2. Anwendungsfall zur Untersuchung der Rauheitsprognose. Grafik: IFW

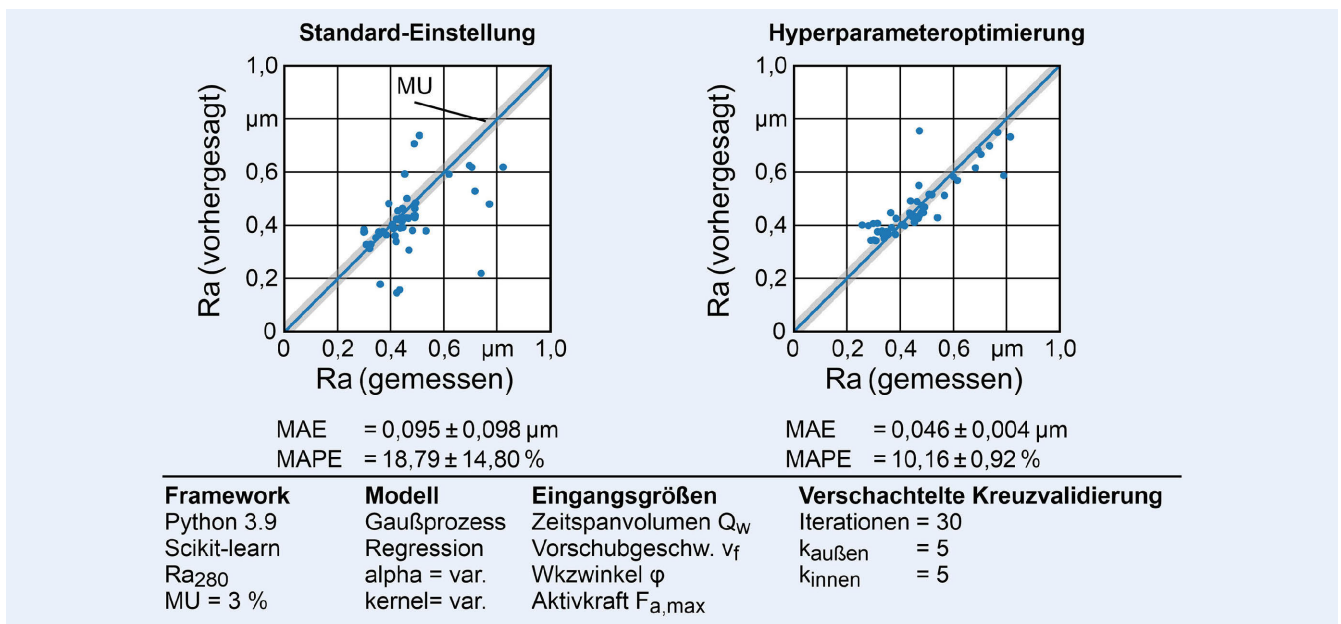


Bild 3. Einfluss der Hyperparameteroptimierung auf die Rauheitsprognose mittels GPR. Grafik: IFW

ses durch das Mehrkomponenten Dynamometer „M9257B“ von Kistler aufgenommen. Im Rahmen der Datenvorverarbeitung wurde aus den Prozesskräften die maximale Aktivkraft $F_{a,\text{max}}$ extrahiert. Sämtliche Daten wurden anschließend durch den Vergleich der Zeitstempel zu einem Datenstrom synchronisiert und dienen als mögliche Eingangsgrößen zur datenbasierten Prognose der Oberflächenrauheit R_a . Daraufhin wurden 1500 Rauheitsdaten auf den Taschenböden mittels „MarSurf LD 130“ ($\lambda_c = 0,8 \text{ mm}$, $l_r = 0,8 \text{ mm}$, $l_n = 4 \text{ mm}$) taktil aufgenommen. Anschließend wurde der mittlere Mittenrauheitswert R_a einer Gesamtmessstrecke l_n extrahiert und mit den oben beschriebenen Daten durch den Vergleich der Achspositionen und Messkoordinaten im Werkstückkoordinatensystem synchronisiert. Die Messunsicherheit (MU) beträgt dabei 3 %. Um Ausreißer im Datensatz zu identifizieren und zu eliminieren, wurden die Daten

mittels K-Nearest-Neighbor Algorithmus ($K = 10$, $n = 20$) geclustert. Die verbleibenden 280 Datenpunkte bildeten daraufhin die Grundlage für die Entwicklung von Prognosemodellen auf Basis des maschinellen Lernens. In Voruntersuchungen erwiesen sich die Support Vector Regression (SVR) und die GPR als geeignete Algorithmen für die weitere Modellierung der Prognoseunsicherheit. Die Implementierung erfolgte in Python unter Verwendung der „Scikit-Learn“ (sklearn) Bibliothek.

Bild 3 zeigt zunächst den Einfluss der Hyperparameteroptimierung auf die Prognosegenauigkeit der Oberflächenrauheit R_a am Beispiel der GPR. Hierzu wurde eine verschachtelte Kreuzvalidierung ($k_{\text{außen}} = 5$, $k_{\text{innen}} = 5$) verwendet. Die Bewertung der Prognoseergebnisse findet somit unter Berücksichtigung von Mittelwert und Standardabweichung von MAE und MAPE nach 30 Wiederholungen statt. Voruntersuchungen haben ergeben,




Bild 4. Ergebnis der Unsicherheitsmodellierung anhand des MAPE-Ansatzes. Grafik: IFW

dass eine 30-fache Wiederholung diesen Effekt sehr gut reduziert. Es zeigt sich, dass durch Variation des Kernels eine signifikante Verbesserung der Prognosegüte erzielt werden konnte. Während der Prognosefehler unter Standard-Einstellungen zwischen $18,79 \pm 14,80 \%$ liegt, kann dieser durch die Anpassung der Hyperparameter auf $10,16 \pm 0,92 \%$ reduziert werden.

Zwar ist dies bereits im Mittel eine stabile Prognose der Oberflächenrauheit, jedoch zeigt Bild 3 auch, dass es weiterhin zu Fehleinschätzungen der Oberflächenrauheit kommt. Insbesondere, wenn das Prognoseergebnis nahe der Qualitätstoleranzgrenze liegt, kann eine Fehleinschätzung zwangsläufig zu einem ungewollten Durchschlupf führen. Somit ist die Notwendigkeit zur weiteren Erforschung von Ansätzen zur Unsicherheitsmodellierung gegeben. Um die Ansätze bewerten zu können, wurden zwei Metriken zur Bewertung der entwickelten Ansätze zur Unsicherheitsmodellierung gemäß Gleichung 1 und 2 definiert. $P_{\text{Erfassung}}$ gibt dabei die Erfassungswahrscheinlichkeit über die Anzahl der im vorhergesagten Unsicherheitsintervall enthaltenen Testdatenpunkte $n_{\text{in,test}}$ zur Gesamtzahl der Probenpunkte im Testdatensatz $n_{\text{all,test}}$ an. Die relative mittlere Intervallbreite \bar{I}_B gibt das arithmetische Mittel der Intervallbreite \hat{y} über die gesamten Daten an und beschreibt die Präzision der Bildung des Unsicherheitsbereichs. Eine geeignete Methode zur Unsicherheitsmodellierung liegt folglich bei einer möglichst hohen Erfassungswahrscheinlichkeit und bei einer möglichst geringen Intervallbreite \hat{y} vor.

$$P_{\text{Erfassung}} = \frac{n_{\text{in,test}}}{n_{\text{all,test}}} \quad (1)$$

$$\bar{I}_B = \frac{1}{n} \sum_{i=1}^n \frac{I_{B,i}}{\hat{y}} \quad (2)$$

Der erste Ansatz umfasst die Berechnung eines konstanten Unsicherheitsniveaus auf Basis des MAPE des Trainingsdatensatzes (MAPE-Ansatz). Dieser gibt den mittleren absoluten prozentualen Fehler an, welcher im Rahmen der Modellentwicklung berechnet wurde. Die Berechnung des Unsicherheitsniveaus U_{MAPE} für den vorhergesagten Qualitätswert \bar{I}_B erfolgt anhand von Gleichung 2:

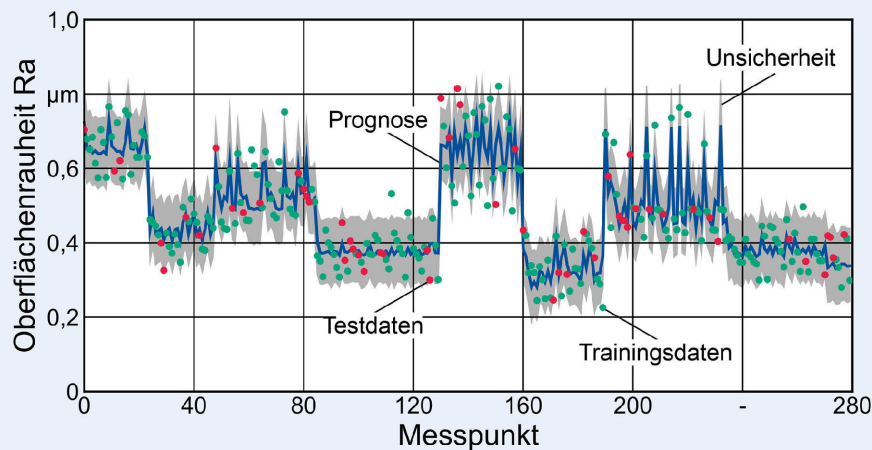
$$U_{\text{MAPE}} = \bar{I}_B \cdot \text{MAPE} \quad (2)$$

Ein wesentlicher Vorteil dieser Vorgehensweise besteht in der einfachen Implementierung der Methode. Allerdings erfolgt zudem eine starke Reduzierung der vorliegenden Komplexität durch die Annahme, dass der Unsicherheitsanteil einem konstanten Wert unterliegt. Dies zeigt sich ebenfalls in der Bewertung der Methode (Bild 4). So konnte eine geringe Erfassungswahrscheinlichkeit $P_{\text{Erfassung}}$ von $60 \pm 5 \%$ ermittelt werden. Die mittlere Intervallbreite \hat{y} beträgt $20 \pm 0 \%$.

Dem vorgestellten Ansatz zur Unsicherheitsmodellierung gegenüber steht der Bootstrapping-Ansatz (BS-Ansatz), der aus einem statistischen Wiederholungstichprobenverfahren besteht. Der Grundgedanke des Bootstrapping liegt darin, eine große Anzahl künstlicher Datensätze zu erzeugen, indem neue Datenpunkte aus dem ursprünglichen Datensatz mehrfach mit zurücklegen gezogen werden [10]. Die Größe des neuen Datensatzes stimmt dabei in der Regel mit der ursprünglichen Größe überein. Das Vorgehen besitzt den Vorteil, dass durch das Resampling von Trainingsdaten eine umfassende Betrachtung der Modellunsicherheit ermöglicht wird. Des Weiteren wird eine inkonstante Modellierung vorgenommen, wodurch eine realitätsnähere Betrachtung der Prognoseunsicherheit erfolgt. Dem gegenüber stehen jedoch ein hoher Implementierungsaufwand sowie notwendige Kenntnisse im Bereich der Statistik. Die Unsicherheit $U_{\text{Bootstrapping}}$ setzt sich gemäß [11] zusammen aus den Unsicherheitsanteilen der Modellvarianz U_{Varianz} , Modellverzerrung U_{Bias} sowie des Stichprobenrauschen U_{Rauschen} . Der Faktor b stellt die relative Überanpassungsrate dar. Die Variable q beschreibt den Faktor zur Berechnung des 95 %-Quantils.

$$U_{\text{Bootstrapping}} = q \cdot ((1 - b) \cdot (U_{\text{Varianz}} + U_{\text{Bias}}) + b \cdot U_{\text{Rauschen}}) \quad (3)$$

Die Erfassungswahrscheinlichkeit konnte mit dem Ansatz gegenüber der Verwendung eines konstanten Unsicherheitsniveaus auf $P_{\text{Erfassung}} = 87 \pm 5 \%$ erhöht werden (Bild 5). Dies entspricht gegenüber dem MAPE-Ansatz eine Steigerung von knapp 45 %. Die Steigerung konnte durch eine deutlich höhere Intervallbreite \hat{y}



Framework	Ra ₂₈₀	Methode	Hyperparameter	Bewertung
Python 3.9	$\bar{x} = 0,47 \mu\text{m}$	BS	$C = 0,5$	Iterationen = 30
Scikit-learn	$s = 0,15 \mu\text{m}$	SVR	$\gamma = 5$	$P_{\text{Erfassung}} = 87 \pm 5 \%$
	$n = 280$		$\epsilon = 0,025$	$I_B = 38 \pm 8 \%$


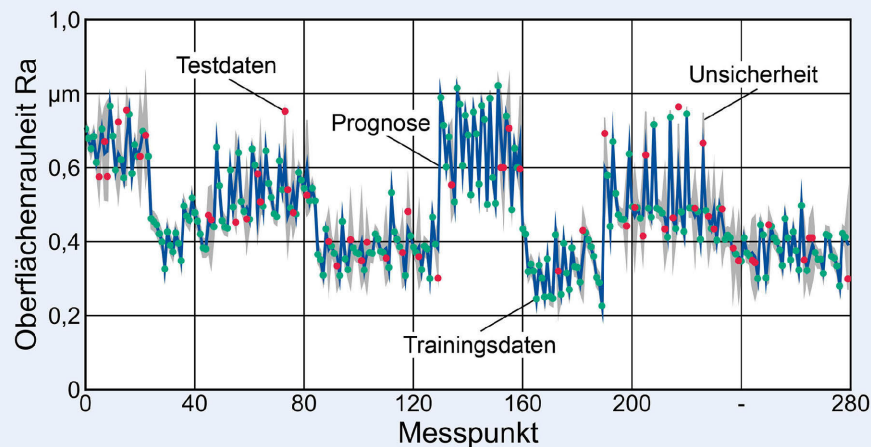


Bild 5. Ergebnis der Unsicherheitsmodellierung anhand des BS-Ansatzes. Grafik: IFW



Framework	Ra ₂₈₀	Methode	Hyperparameter	Bewertung
Python 3.9	$\bar{x} = 0,47 \mu\text{m}$	GPR	$\alpha = 0,01$	Iterationen = 30
Scikit-learn	$s = 0,15 \mu\text{m}$			$P_{\text{Erfassung}} = 92 \pm 4 \%$
	$n = 280$			$I_B = 20 \pm 17 \%$




Bild 6. Ergebnis der Unsicherheitsmodellierung anhand des GPR-Ansatzes. Grafik: IFW

erzielt werden. Diese beträgt bei Verwendung des BS-Ansatzes $38 \pm 8 \%$.

Zuletzt wurde die GPR zur Modellierung der Prognoseunsicherheit angewandt (GPR-Ansatz). Eine Besonderheit dieses Verfahrens besteht in der Berechnung einer Vorhersageverteilung, anstelle eines einzelnen -werts. Folglich liegt zu jedem Prognoseergebnis ebenfalls die zugehörige Standardabweichung s vor, welche den Indikator der Prognoseunsicherheit darstellt (siehe Gleichung 4). Die Variable q beschreibt den Faktor zur Berechnung des 95 %-Quantils.

$$U_{\text{Gauß}} = q \cdot s \quad (4)$$

Ein Vorteil der Methode besteht somit wie schon beim BS-Ansatz in der Modellierung einer variierenden Prognoseunsicherheit sowie in einer vergleichsweise einfachen Implementierung.

Jedoch ist dieses Vorgehen lediglich auf die GPR begrenzt und ist derzeit nicht auf andere Regressionsmethoden anwendbar. Für den vorliegenden Anwendungsfall kann dem Ansatz der GPR die höchste Erfassungswahrscheinlichkeit $P_{\text{Erfassung}}$ ($92 \pm 4 \%$) zugeordnet werden. Gegenüber dem MAPE-Ansatz ist eine Steigerung von $P_{\text{Erfassung}}$ um knapp 53 % möglich (Bild 6). Die Intervallbreite beträgt im Mittel $20 \pm 17 \%$. Es im Mittel vergleichbar zum MAPE-Ansatz. Aufgrund der inkonstanten Modellierung liegt jedoch eine deutlich höhere Streuung von \hat{y} vor.

4 Berücksichtigung von Unsicherheiten in der adaptiven Prüfplanung

Das Ziel der adaptiven Prüfplanung besteht in der Minimierung konventioneller Prüfaufwände durch die Interpretation datengetriebener Qualitätsprognosen. Vor diesem Hintergrund

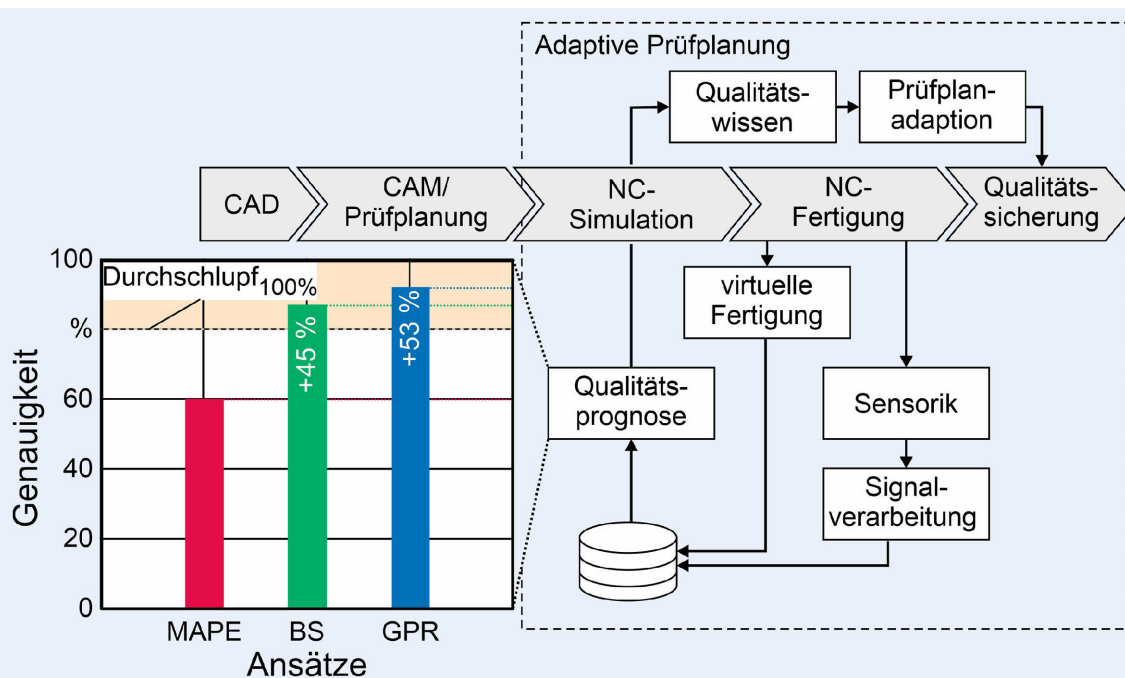


Bild 7. Zusammenfassung der erzielten Ergebnisse zur Unsicherheitsmodellierung. Grafik: IFW

besitzt die Unsicherheitsmodellierung eine herausragende Bedeutung in der Interpretation virtueller Prüfergebnisse und der Entscheidung darüber, welche Prüfaufwände mit ausreichender Sicherheit vermieden werden können (**Bild 7**). So konnte gezeigt werden, dass die Annahme eines konstanten Unsicherheitsanteils (hier: MAPE-Ansatz) für eine sichere Interpretation der virtuellen Prüfergebnisse nicht zielführend ist. Vergleichsweise ist bei einer manuellen 100 %-Prüfung von einem verbleibenden Durchschlupf von 100 % bis zu 20 % auszugehen [12]. Die Ergebnisse zeigen jedoch, dass sowohl der BS- als auch GPR-Ansatz zu einer sicheren Interpretation der Qualitätsergebnisse führen können. Die Verwendung des MAPE-Ansatzes hingegen liefert eine geringe Intervallbreite \hat{y} . Aufgrund der geringen Erfassungswahrscheinlichkeit ist eine Verwendung dieses Ansatzes jedoch nicht zielführend. Durch die Verwendung des BS-Ansatzes konnte die Erfassungswahrscheinlichkeit gegenüber dem MAPE-Ansatz um 45 % erhöht werden. Durch die Verwendung der GPR ist sogar eine Steigerung der Genauigkeit von 53 % zu erzielen. Aufgrund der geringeren Intervallbreite \hat{y} ist im vorliegenden Anwendungsfall die Verwendung des GPR-Ansatzes zur Unsicherheitsmodellierung zu empfehlen. Die Ergebnisse zeigen somit, dass eine datenbasierte Qualitätsprognose auf Grundlage des maschinellen Lernens eine zuverlässige virtuelle Prüfung der Werkstückqualität ermöglicht.

5 Zusammenfassung und Ausblick

Die Unsicherheitsmodellierung besitzt innerhalb der adaptiven Prüfplanung eine besondere Bedeutung, wenn es um die Interpretation der virtuellen Prüfergebnisse geht. So können konventionelle Prüfaufwände lediglich reduziert werden, wenn die Qualitätsprognosen eine entsprechende Sicherheit besitzen. Ein stets verbleibender Modellfehler erschwert die Interpretation jedoch insbesondere bei Qualitätswerten nahe der Toleranzgrenze. Im vorliegenden Beitrag konnte gezeigt werden, dass die Unsicher-

heitsmodellierung anhand eines BS-Ansatzes (87 %) sowie durch Verwendung der GPR (92 %) sehr gute Erfassungswahrscheinlichkeiten zur sicheren Interpretation der Qualitätsprognosen liefern. Mithilfe des BS-Ansatzes ist es zudem möglich, die Unsicherheitsmodellierung ebenfalls über die GPR hinaus durchzuführen. Im weiteren Verlauf des Forschungsvorhabens erfolgt die Evaluierung der Ansätze unter variierenden Fertigungsszenarien (Materialwechsel, Extrapolation von Prozessstellgrößen, Werkzeugwechsel, Geometriewechsel).

FÖRDERHINWEIS

Förderorganisation (Investitions- und Förderbank Niedersachsen) und Förder-Projekt-Kennungen (ZW1 – 80159725)

DANKSAGUNG

Das Forschungsvorhaben „VerticalE2E – Vertikal integrierte, nachhaltige End-to-End-Fabrik“ (ZW1 – 80159725) wird von der Investitions- und Förderbank Niedersachsen gefördert. Ein großer Dank gilt ebenfalls dem Projektpartner Premium Aerotec.

Literatur

- [1] Hofmann, R.; Gröger, S.: Prüfplanung auf Basis der Geometrischen Produktspezifikation als Schlüsselkompetenz in Industrie 4.0. In: Schmitt, R. H. (Hrsg.): Potenziale Künstlicher Intelligenz für die Qualitätswissenschaft. Berlin: Springer-Verlag 2020, S. 73–88
- [2] Denkena, B.; Wichmann, M.; Reuter, L.: Kostenvorteile durch adaptive Prüfplanung. Zeitschrift für wirtschaftlichen Fabrikbetrieb 117 (2022) 4, S. 178–181

- [3] Naser, M. Z.; Alavi, A. H.: Error Metrics and Performance Fitness Indicators for Artificial Intelligence and Machine Learning in Engineering and Sciences. *Architecture, Structures and Construction* (2021), S. 1–19
- [4] DIN Deutsches Institut für Normung e.V.: Qualitätsmanagementsysteme – Anforderungen an Organisationen der Luftfahrt, Raumfahrt und Verteidigung. Berlin: Beuth Verlag 2018
- [5] Kowalczyk, M.; Tomczyk, K.: Procedure for Determining the Uncertainties in the Modeling of Surface Roughness in the Turning of NiTi Alloys Using the Monte Carlo Method. *Materials* 13 (2020) 19, S. 1–14
- [6] Sun, H.; Zhao, S.; Zhou, L.; Yan, R.; Huang, H.: Uncertainty calibration and quantification of surrogate model for estimating the machining distortion of thin-walled parts. *The International Journal of Advanced Manufacturing Technology* 120 (2022), S. 719–741
- [7] Liu, W.; Wang, P.; You, Y.: Surface roughness prediction using multi-source heterogeneous data and Bayesian quantile regression in milling process. *Journal of Manufacturing Processes* 95 (2023), S. 446–460.
- [8] Bernados, P.G.; Vosniakos, G.-C.: Predicting the surface roughness in machining: a review. *International Journal of Machine Tools & Manufacture* 43 (2003), S. 833–844
- [9] Denkena, B.; Böß, V.: Technological NC Simulation for Grinding and Cutting Processes Using CutS. In: Arrazola P. J. (Hrsg.): *Proceedings of the 12th CIRP Conference in Modelling of Machining Operations*. Conastia-San Sebeastian: CIRP Proceedings, S. 563–566.
- [10] Efron, B.: Bootstrap Methods: Another Look at the Jackknife. *Annals of Statistics* 7 (1979), S. 1–26.
- [11] Efron, B.; Tibshirani, R.: Improvements on Cross-Validation: The 632+ Bootstrap Method. *Journal of the American Statistical Association* 92 (1997) 438, S. 548–560
- [12] Masing, W.: Prüfrisiko. *Qualität und Zuverlässigkeit* 15 (1970) 8, S. 191–192



Prof. Berend Denkena
Foto: IFW

Dr.-Ing. Marcel Wichmann

Leon Reuter, M.Sc.

Universität Hannover
Institut für Fertigungstechnik
und Werkzeugmaschinen IFW
An der Universität 2, 30823 Garbsen
Tel. +49 511 / 762-18211
reuter@ifw.uni-hannover.de
www.ifw.uni-hannover.de

LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons
Namensnennung 4.0 International (CC BY 4.0)