

Erklärbare KI-Ansätze zur Rüstzeitoptimierung in der CNC-Werkzeugherstellung

Künstliche Intelligenz und Produktionssteuerung

D. Kiefer, F. Grimm, J. Höllig, C. Van Dinther, T. Straub, G. Bitsch

ZUSAMMENFASSUNG Lange Rüstzeiten beeinträchtigen die CNC-Werkzeugherstellung durch reduzierte Flexibilität, niedrige Maschinenauslastung und gesteigerten Planungsaufwand, was Lieferverzögerungen und Produktionsengpässe begünstigt. Ökonomisch binden sie Kapital, erhöhen die Produktionskosten, limitieren die Auftragsflexibilität, treiben Lagerkosten hoch und lassen Marktchancen ungenutzt. Erklärbare KI-Modelle können durch die Analyse von Prozessdaten Muster in langen Rüstzeiten identifizieren und Anhaltspunkte für Verbesserungen transparent aufzeigen und somit die Effizienz steigern und Kosten reduzieren.

STICHWÖRTER

Erklärbare Künstliche Intelligenz,
Produktionssteuerung, Industrie 4.0

Explainable AI approaches for setup time optimization in CNC tool manufacturing – Artificial intelligence and production control

ABSTRACT Long set-up times impair CNC tool production due to reduced flexibility, lower machine utilization and increased planning effort, which promotes delivery delays and production bottlenecks. Economically, they tie up capital, increase production costs, limit order flexibility, drive up storage costs and leave market opportunities untapped. By analyzing process data, explainable AI models can identify patterns in long set-up times and transparently highlight points for improvement, thereby increasing efficiency and reducing costs.

1 Motivation

Die deutsche Produktionstechnik ist geprägt vom Mittelstand mit spezialisierten Produkten und daher von hoher Variantenvielfalt und geringen Stückmengen [1-3]. Dies stellt die klassische Künstliche Intelligenz (KI), die im Wesentlichen auf der statistischen Auswertung extrem großer Datenmengen beruht [4], vor Herausforderungen. Machine Learning Modelle erzielen im Bereich der Bildverarbeitung sowie in weiteren Bereichen große Erfolge, zum Beispiel der Spracherkennung. Derzeit funktionieren solche Modelle nur sehr eingeschränkt bei kleinen Datensätzen, das heißt bei Datensätzen mit einer kleinen Anzahl an Stichproben mit hochdimensionalen Merkmalen [5].

Die Herausforderungen für die Produktion kundenspezifischer Produkte sind groß, insbesondere für qualitativ hochwertige Produkte. Hinsichtlich der Einhaltung von Qualitätsparametern besteht die Schwierigkeit darin, dass viele Faktoren Einfluss auf die Rüstzeit haben. So beeinflussen sowohl die Bauteile und deren Beschaffenheit (geometrische Maße, Abweichungen, Legierungen etc.) als auch die Parametereinstellungen der Produktionsmaschinen die Rüstzeit. Auch die Kombination verschiedener Faktoren können zu hohen Rüstzeiten führen, obwohl ein Faktor allein unkritisch wäre. Die Stückzahlen bei Spezialprodukten sind in der Regel klein, während die Kombinationsmöglichkeiten der Faktoren einen großen Parameterraum bilden. Zudem ist die spezifische Auslegung der Produktion aufwendig [6]. Die Minimierung von Rüstzeiten für eine maximale Maschinenauslastung

und die Vermeidung von Qualitätsmängeln sind entscheidende Stellschrauben bei Produktionskosten für den Produktionsstandort Deutschland [1, 6-8].

Die Wirkzusammenhänge der komplexen Produktionsprozesse sind häufig nur unvollständig abgebildet und verstanden. Datenintensive Modellierungsverfahren aus dem Bereich der KI mit dem Spezialgebiet des maschinellen Lernens bieten eine vielversprechende Möglichkeit Korrelationen aufzudecken und Kausalzusammenhänge zu beschreiben [1].

Ziel dieser Arbeit ist es daher, Verfahren der KI speziell vor dem Hintergrund der Produktionstechnik zu testen. Im Rahmen eines exemplarischen Anwendungsfalles der Herstellung von CNC-Spezialwerkzeuge durch einen CNC-Schleifprozess werden Problemstellungen der Produktionstechnik erörtert.

Die Optimierung der Rüstzeiten von Schleifmaschinen zur Herstellung von CNC-Werkzeugen, wie beispielsweise hochpräzise Nutstoßwerkzeuge, ist ein entscheidender Faktor für die betriebliche Effizienz und die Produktionskapazität [9]. Längere Rüstzeiten führen zu nicht produktiv nutzbaren Ressourcen, was die Reaktionsfähigkeit auf die Marktnachfrage beeinträchtigt und sich möglicherweise auf die finanzielle Leistungsfähigkeit auswirkt [10]. Als Reaktion auf diese Herausforderung versucht die Industrie kontinuierlich, ihre Rüstverfahren zu verbessern, um schnell zwischen verschiedenen Produktvarianten wechseln zu können, ohne die Produktqualität zu beeinträchtigen [11]. Die inhärente Komplexität von Rüstprozessen führt jedoch häufig zu Schwierigkeiten bei der Rationalisierung und Optimierung von

Abläufen [12]. In dieser Arbeit wird ein datengesteuertes Entscheidungsmodell präsentiert, das erklärbare KI nutzt, um die Rüstzeiten von Schleifmaschinen zu verbessern [13]. Das Modell zielt darauf ab, die komplizierten Beziehungen zwischen verschiedenen Rüstparametern zu entschlüsseln, um ein besseres Verständnis und eine Optimierung dieser Prozesse zu erlauben [14]. Durch die Identifizierung von Engpässen und gezielte Verbesserungen zielt das vorgeschlagene Modell darauf ab, die Rüstzeiten erheblich zu reduzieren, die Produktivität zu steigern und zur wirtschaftlichen Nachhaltigkeit des Anwendungspartners in der Industrie beizutragen [15].

In den nachfolgend beschriebenen Abschnitten werden Methoden der Erklärbaren KI behandelt und ein spezifisches KI-gestütztes Modell vorgestellt, einschließlich seiner Entwicklung und praktischen Anwendung. Zudem werden potenzielle Einsatzgebiete beleuchtet und zukünftige Forschungsansätze zur Optimierung der Rüstzeiten in Schleifmaschinenprozessen diskutiert.

2 Erklärbare KI

In komplexen betrieblichen Kontexten wird oft auf nichtlineare Machine Learning Modelle zurückgegriffen, um mehrdimensionale Beziehungen abzubilden [16]. Die Interpretation der Entscheidungsfindung in solchen Modellen ist jedoch nicht immer intuitiv [17]. Zur Lösung dieses Problems wurden Methoden entwickelt, die die Nachvollziehbarkeit der Schlussfolgerungen nichtlinearer Modelle verbessern. Diese Ansätze, bekannt unter dem Sammelbegriff Erklärbare KI, fokussieren sich insbesondere auf die Analyse der Merkmalswichtigkeit und die Zuschreibung von Einflüssen auf spezifische Merkmale.

Bisher wurden die Konzepte der Merkmalswichtigkeit und der Merkmalszuordnung in der Regel unabhängig voneinander behandelt. Im Folgenden werden beide Ansätze detailliert erläutert:

- Die Bewertung der Merkmalswichtigkeit zielt darauf ab, den Einfluss einzelner Merkmale auf die Ergebnisse eines Vorhersagemodells zu bestimmen. Eine Methode ist der Vergleich der Modellleistung mit und ohne das betreffende Merkmal, um dessen Beitrag unter Einbeziehung aller möglichen Wechselwirkungen zu bewerten. Eine weitere Methode misst die Auswirkungen auf die Vorhersagegenauigkeit bei zufälliger Modifikation eines Merkmals. Daraüber hinaus existieren modellspezifische Techniken für die Ermittlung der Merkmalswichtigkeit, wie sie bei Entscheidungsbäumen und Support-Vektor-Maschinen Anwendung finden. [18, 19]
- Die Merkmalszuweisung bewertet den spezifischen Beitrag eines Merkmals zur Vorhersage eines Modells. Dabei wird untersucht, inwiefern eine Veränderung des Merkmals die Vorhersage beeinflusst. In linearen Modellen wird dieser Beitrag durch die Koeffizienten dargestellt. Bei nichtlinearen Modellen kann die Merkmalszuweisung mittels partieller Abhängigkeitsdiagramme oder durch lokal interpretierbare, modellunabhängige Erklärungen erfolgen, um den Einfluss eines Merkmals auf die Vorhersage zu quantifizieren. [13, 20]

Die SHAP-Wert-Methode vereint die Konzepte der Merkmalswichtigkeit und -zuweisung, um die Entscheidungsfindung in Vorhersagemodellen transparent zu machen, indem sie Vorhersagen in einzelne Merkmalsbeiträge, die sogenannten SHAP-Werte, aufgliedert. Sie basiert auf der Kombination aus lokalen Modellerklärungen und spieltheoretischen Prinzipien, wobei SHAP-Werte individuell für jede Beobachtung innerhalb eines

Merkmalsvektors berechnet werden [21]. Diese Methode erlaubt eine detaillierte Analyse sowohl auf lokaler als auch auf globaler Ebene und findet in dieser Arbeit Anwendung, um komplexe Zusammenhänge zwischen Produktionsparametern und der Rüstzeit in dem nachfolgenden beschriebenen Fertigungssystem zu entschlüsseln.

3 Erklärbares Prognosemodell

In diesem Abschnitt wird ein auf Daten basierendes Prognosemodell entworfen, um die Rüstzeiten in der Produktion zu reduzieren. Dabei wird zunächst ein Produktionsumfeld skizziert, die Problemstellung dargelegt und anschließend die Spezifikationen des Modells formuliert. In diesem Abschnitt wird ein KI-basiertes Modell zur Entscheidungsunterstützung entwickelt, mit dem Ziel, die Rüstzeiten in der Fertigung zu reduzieren, insbesondere beim Einrichten von Schleifmaschinen. Zunächst wird eine formale Werkstattumgebung definiert, um anschließend das Problem der Rüstzeitineffizienz zu umreißen und die detaillierten Spezifikationen des Modells zu liefern.

3.1 Rahmenbedingungen des Produktionsumfeld

Das Produktionsumfeld umfasst zehn Gruppen von Arbeitsplätzen, organisiert nach den spezifischen Produktfamilien, die sie fertigen. Im Fokus der Betrachtung steht eine Gruppe, ausgestattet mit CNC-gesteuerten 5-Achsen-Fräsmaschinen. Diese Fräsmaschinen wurden vom Anwendungspartner aus der Industrie so modifiziert, dass sie zum Schleifen statt zum Fräsen verwendet werden.

In dem Produktionsumfeld werden sequenzielle Prozesse analysiert, wobei jeder durch spezifische Parameter charakterisiert wird, die potenziell auf die Rüstzeit Einfluss nehmen. Das Gesamtergebnis dieser Prozesse wird anhand der Rüstzeiten bewertet. Der Rüstvorgang wird als Gesamtheit aller Schritte definiert, die nötig sind, um eine Maschine von der Produktion des letzten guten Stücks eines Auftrags auf die Produktion des ersten guten Stücks des nächsten Auftrags umzustellen (siehe Gleichung 1) [22]. Dies umfasst Aktivitäten wie den Austausch von Werkzeugen und Formen, Reinigungsarbeiten, die Anpassung von Maschineneinstellungen sowie das Be- und Entladen von Rohlingen.

$$\text{GesamtRüstzeit} = \sum (\text{Zeit für jede einzelne Rüstaufgabe}) \quad (1)$$

In dem Produktionsumfeld werden Produktionsparameter wie Wartungsdaten, Produktionsdaten, Sensorikdaten, Maschinen-daten, Maschinenparameter, Werkzeugdaten und Produktdaten erzeugt. Ein Datenmodell in Form eines Entity-Relationship-Diagramms bildet die Beziehungen zwischen diesen Datentypen ab und ermöglicht so eine effiziente Datenverwaltung und -analyse.

Das Fertigungssystem generiert Daten zu Produktionsparametern x und Rüstzeitergebnisse y . Insgesamt gibt es $j = 1, \dots, N$ Produktionsparameter und $i = 1, \dots, M$ Messwerte (Rüstvorgänge).

3.2 Problembeschreibung

Ziel ist es, Kombinationen von Produktionsparametern N mit langen Rüstvorgängen M zu vermeiden. Es gibt Kombinationen

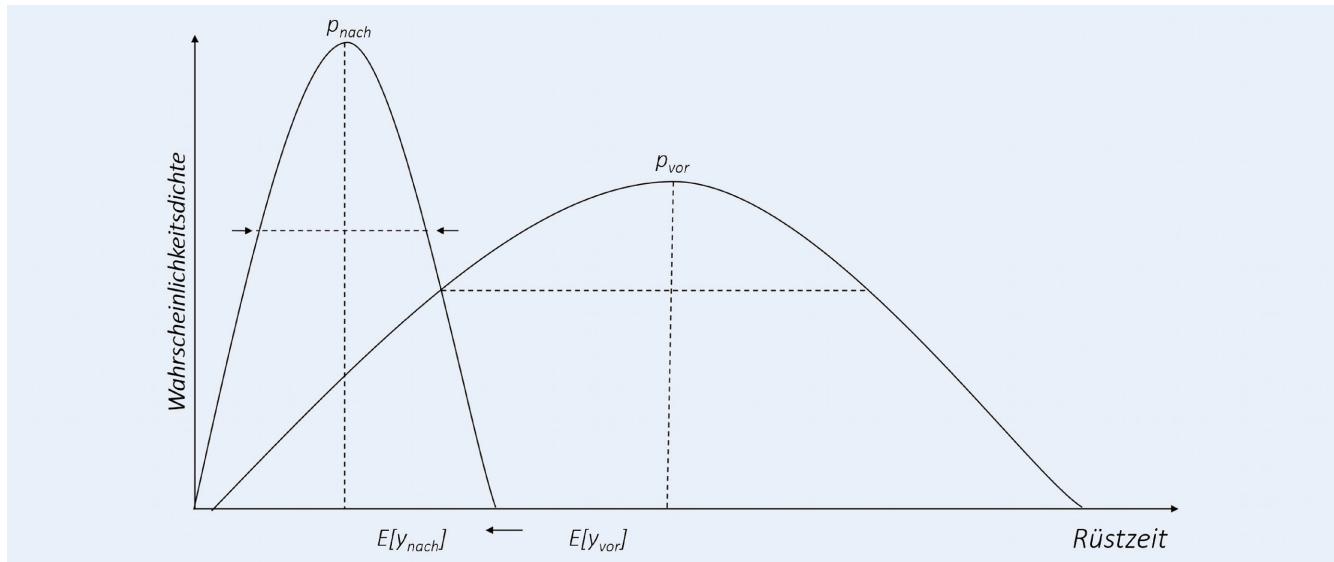


Bild 1. Beispiel für die zu erwartende Rüstzeit vor und nach der Verbesserung. *Grafik: ESB Business School, Reutlingen University*

aber auch Abfolgen aufeinander, welche die Systemleistung, das heißt die Gesamtzeit des Rüttvorgangs, wesentlich beeinflussen. Dieses Ziel steht im Einklang mit der Qualitätsmanagementtheorie zur Verringerung von Rüstzeiten, die vorschlägt, die Ursachen der Variation anzugehen [11, 23–25].

In der Praxis führt jeder Rüttvorgang zu Ergebnissen, die eine unterschiedliche Dauer aufweisen. Für die Zwecke dieser Diskussion gehen wir davon aus, dass kürzere Rüstzeiten wünschenswert sind. Die Streuung um den Mittelwert der Rüstzeit liefert ein Maß für die potentielle Verbesserung des Systems. Wenn es Schwankungen bei den Rüstzeiten gibt, besteht die Möglichkeit, aus schnelleren Rüstzeiten zu lernen (Verteilungsanfang) und langsamere zu vermeiden (Verteilungsende) siehe die Verteilung in **Bild 1**.

Daher ist das Ziel in einem Produktionsumfeld die Rüstzeiten vom rechten Ende Verteilung zu dem linken Start der Verteilung zu verschieben. Das kann erreicht werden, wenn die Produktionsparameterkombinationen, welche für Schwankungen der Gesamtrüstzeiten verantwortlich sind, vermieden werden. Hierdurch kann implizit die durchschnittliche Rüstdauer verringert werden.

Ein Vorgehen hierbei kann sein, zunächst die Prozesse zu identifizieren, die das größte Verbesserungspotenzial bieten, und dann Verbesserungsmaßnahmen lediglich für diese ausgewählten Prozesse und Parameter zu definieren. Die Umsetzung von Verbesserungsmaßnahmen hängt von den spezifischen Eigenschaften der Produktionsparameter ab. Bei einigen Produktionsparametern ist es möglich, die absoluten Werte direkt anzupassen. Wenn beispielsweise die Temperatur in einem bestimmten Prozess einen Einfluss auf die Prozessqualität hat, könnte eine Verbesserungsmaßnahme darin bestehen, die Temperaturniveaus zu justieren. Allerdings lassen sich in manchen Prozessen die Produktionsparameter nicht direkt verändern.

3.3 Modell Definition

Ausgangspunkt für das Modell sind historische Fertigungsdaten $\{x^i, y^i\}_{i=1}^M$. Basierend auf diesen Daten wird ein nichtlineares Modell f erlernt, dass die Zusammenhänge zwischen Produktionsparametern $x^{(i)}$ und der Rüstzeit $y^{(i)}$ nachbildet. Das

Modell $f: \mathbb{R}^N \rightarrow \mathbb{R}$ basiert auf einem, das auf Grundlage vergangener Beobachtungen der Produktionsparameter und Rüstzeiten geschätzt wird.

Dies kann ein beliebiges Vorhersagemodell f sein, das hochdimensionale und nichtlineare Beziehungen emulieren kann (zum Beispiel Entscheidungsbaum-Verfahren, neuronale Netze). Das Modell f wird mit dem Ziel geschätzt, den Fehler zwischen der wahren und der geschätzten Rüstzeiten zu minimieren,

$$\min_f \mathbb{E} [\ell(y, f(x))] \quad (2)$$

wobei ℓ eine konvexe Verlustfunktion ist (zum Beispiel mittlerer quadratischer Fehler). Wenn f gut spezifiziert ist, erhalten wir ein Metamodell der Prozesse, das erklärt, wie verschiedene Produktionsparameter und die Rüstzeit zusammenhängen.

Die zugrundeliegenden Beziehungen im Produktionsumfeld berechnen wir über die SHAP-Wert-Methode [21]. Konkret verwenden wir SHAP-Werte, um zu erklären, wie sich die geschätzte Rüstzeit ändert, wenn der Effekt eines Produktionsparameters weggelassen wird. Hierbei erklärt die SHAP-Wert-Methode das Modell f lokal bei jeder Beobachtung i . Die Erklärung erfolgt formal durch additive Merkmalszuweisungen, die sich zur Ausgabe des Metamodells aufsummieren. In unserem Kontext gibt ein SHAP-Wert die geschätzte Abweichung von der erwarteten Rüstzeit $E[f(x)]$ an, die einem beobachteten Produktionsparameter $x^{(i)}$ zugeschrieben werden kann. Negative SHAP-Werte deuten auf eine Verringerung, positive auf eine Erhöhung der geschätzten Rüstzeit hin. Je größer der absolute SHAP-Wert, desto größer die geschätzte Veränderung in der Rüstzeit. Die Berechnung von SHAP-Werten wird für alle Beobachtungen wiederholt und liefert so Merkmalszuweisungen.

Die SHAP-Wert-Methode garantiert drei Eigenschaften:

- Fehlzuweisung,
- Konsistenz,
- und lokale Genauigkeit.

In dem vorliegenden Kontext gewährleistet die Fehlzuweisung, dass abwesende Produktionsparameter keine Merkmalszuweisung erhalten. Konsistenz ist erforderlich, um sinnvolle Vergleiche von Merkmalszuweisungen über Produktionsparameter hinweg zu er-

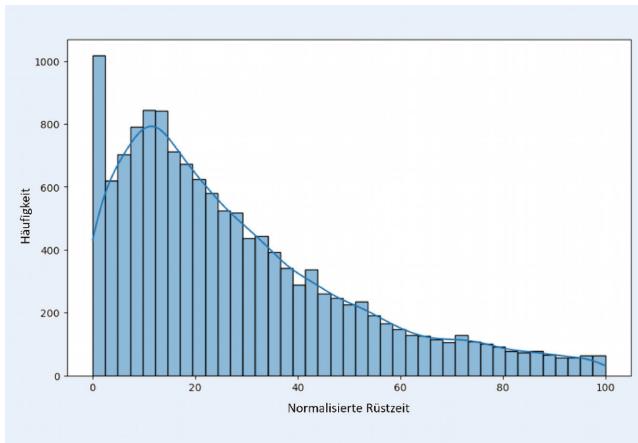


Bild 2. Histogramm der Normalisierten Rüstzeit.
Grafik: ESB Business School, Reutlingen University

möglichen. Lokale Genauigkeit gewährleistet, dass sich die Merkmalszuweisungen zur Modellausgabe aufsummieren und somit eine Schätzung der Veränderungen in der Rüstzeit liefern.

4 Anwendung in der CNC-Werkzeugherstellung

Die Herstellung von CNC-Werkzeugen umfasst in der Regel mehrere miteinander verbundene Prozesse, deren Durchführung Minuten bis Stunden in Anspruch nimmt. Aufgrund der hohen Komplexität, welche sich durch die Toleranzen des zu fertigenden Werkzeugs ergeben, ist es eine Herausforderung, die treibenden Faktoren der Rüstzeit zu identifizieren.

Daher stehen Lohnfertiger beziehungsweise Werkzeughersteller häufig vor erheblichen Engpässen in der Produktion. Die Engpässe können durch die belegten Maschinen, wie aber auch im Zuge des Fachkräftemangels durch die Facharbeiter kommen, welche in langen Rüstprozessen gebunden sind. Vor diesem Hintergrund verspricht die Verbesserung der Rüstzeit eine bedeutende wirtschaftliche Auswirkung zu haben.

Der Anwendungspartner ist ein deutsches KMU, welches führend in der Produktion von Sonder- und Standardwerkzeugen ist. Das Ziel der Zusammenarbeit ist zum einen die Zusammenhänge und Muster von unvorteilhaft langen Rüstzeiten transparent aufzuzeigen und zum anderen eine bessere Handlungsalternative vorzuschlagen beispielsweise in Form einer anderen zu präferierende Maschine für das zu produzierende spezifische Produkt zu wählen.

4.1. Historische Daten

Der Anwendungspartner hat dem Autorenteam historische Daten von $M=1875$ Rüstvorgänge bereitgestellt. Jeder Rüstvorgang ist beschrieben von $N = 144$ Produktionsparametern von $K = 8$ verschiedenen Maschinen.

Das Unternehmen schützte vertrauliche Informationen, indem es die Rüstzeit zwischen 0 und 100 skaliert:

$$y^{(i)} = 100 \times \frac{\mu^{(i)} - \mu_{\min}}{\mu_{\max} - \mu_{\min}} \quad (3)$$

Durch diese Normalisierung bleibt das Verteilungsmuster erhalten, wodurch dennoch die tatsächlich erzielten Verbesserungen angeben können.

4.2 Deskriptive Statistik

Die Verteilung der normalisierten Rüstzeit unserer Trainingsdaten ist in **Bild 2** dargestellt.

Die durchschnittliche normalisierte Rüstzeit liegt bei 28,01 (Standardabweichung von 22,95). Ungefähr 50 % der Rüstprozesse haben eine normalisierte Rüstzeit von über 21,87. Laut unserem Industriepartner können Rüstzeiten mit einer normalisierten Rüstzeit von mehr als 22,00 als verbesserungswürdig eingestuft werden, da diese die vorgegebene Sollzeit nicht einhalten.

In Bezug auf den vorliegenden Datensatz entspricht dies in etwa 45 % der Rüstprozesse. Das Ziel des hier präsentierten Modells besteht darin, Parameterkombinationen zu vermeiden, welche dem rechten Teil der Verteilung zugehörig sind. Die **Tabelle** listet beispielhafte Produktionsparameter auf, die in den Herstellungsprozessen erfasst wurden.

Aus Gründen der Vertraulichkeit bezieht sich das Autorenteam später nur auf die anonymisierten Produktionsparameter $x^{(i)}$. Im Allgemeinen unterscheidet man zwischen Produktionsparametern auf Prozess- und Produktebene. Prozessparameter beschreiben maschinenbezogene Eigenschaften (zum Beispiel der in einer Maschine gemessene durchschnittliche Druck), während sich Produktparameter auf die physischen Produkteigenschaften während der Herstellung beziehen.

4.3 Implementierungsinformation des Modells

Das Metamodell wird auf der Grundlage aller Produktionsparameter und der normalisierten Rüstzeit mithilfe von „XGBoost“ geschätzt [26]. XGBoost gehört zur Kategorie der Boosting-Baum-Ensemble-Algorithmen, die für ihre gute Leistung bei komplexen Datensätzen bekannt sind und bereits in anderen betrieblichen Anwendungen eingesetzt wurden [16, 27]. Im vorliegenden Kontext finden gängige Verfahren Anwendung, wobei die Daten in einen Trainingssatz (80 % der Daten) zur Schätzung von Parametern und einen Holdout-Satz (20 %) zur Bewertung der Modellierungsleistung unterteilt werden. Der Trainingssatz enthält 1500 Rüstprozesse und der Holdout-Satz enthält 375 Rüstprozesse. Das Metamodell wird ausschließlich auf der Grundlage des Trainingssatzes trainiert und abgestimmt (Rastersuche mit Kreuzvalidierung für die Optimierung der Hyperparameter). Berechnet werden die Merkmalszuordnungen aller Produktionsparameter mit der Baumimplementierung der SHAP-Wertmethode (zu Einzelheiten siehe [21]).

5 Ergebnisse

Die Bestimmung des prognostizierten Behandlungseffekts erfolgt durch statistische Analysen historischer Rüstprozesse im Holdout-Set. Um eine Überanpassung zu vermeiden, muss der prognostizierte Behandlungseffekt für die ausgewählten Verbesserungsmaßnahmen auf Beobachtungen beruhen, die nicht in die Schätzung des Modells f selbst eingeflossen sind. Zu diesem Zweck werden die 375 Rüstprozesse im Holdout-Set betrachtet. Der Boxplot zeigt die normalisierte Rüstzeit von den Beobachtungen aus dem Holdout-Set, welche auf den prognostizierten

Tabelle. Beispielhafte Produktionsparameter.

Beschreibung	Produktionsparameter	Einheit	Level
Schleifdorn	x101	-	Prozess
Rohlingsdicke	x202	Millimeter	Produkt
...
Ähnlichkeitskoeffizient	x203	-	Produkt
Maschinenstörungen Anzahl	x301	-	Maschine

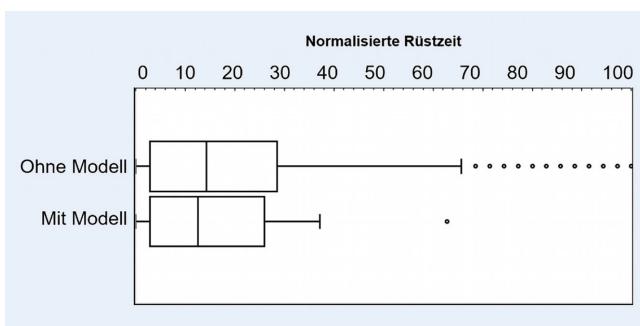


Bild 3. Prognostizierter Effekt durch das Modell.
Grafik: ESB Business School, Reutlingen University

Kombinationen des Modells gerüstet werden würden mit den Daten, welche kein Modell hatten. Die Länge der Whisker ist durch den 1,5er Interquartilsbereich gegeben, und das 50 %-Quantil ist als Linie hervorgehoben.

Der Boxplot zeigt, dass durch das Modell die normalisierte Rüstzeit reduziert werden kann. Es sind vor allem zwei Dinge ersichtlich. Erstens werden Ausreißer reduziert, welche zu langen Rüstzeiten führen. Zweitens wird hierdurch der Mittlere Wert der Rüstzeit reduziert. Die Rüstzeiten mit Modell betragen im Durchschnitt 6 % niedrigere Werte. Der hochgerechnete Behandlungseffekt ergibt sich aus dem mittleren Unterschied im normalisierten Ertrag, der sich auf 6 Einheiten beläuft.

Bei 375 Rüstvorgängen sind das bereits 2250 Einheiten, womit 160 mehr Rüstvorgänge in derselben Zeit, mit denselben Maschinen, etc. absolviert werden können. Das ermöglicht eine flexiblere Produktionsplanung. Erste Schätzungen gehen von über 11500 mehr Rüstvorgängen im Jahr aus, lediglich in der einen betrachteten Arbeitsplatzgruppe.

Eine Analyse historischer Beobachtungen reicht nicht aus, um nachzuweisen, dass das Modell auch in Zukunft wirksam sein wird. Daher wird ein längeres Feldexperiment bei dem Industriepartner vorgenommen.

5.1 Gesamtbedeutung von Erklärbaren KI-Ansätzen

Im vorherigen Abschnitt wurde davon ausgegangen, dass dem Modell gefolgt worden ist in der Anwendung der Parameterkombination. Forschung zeigt aber, dass die Mitarbeiter skeptisch gegenüber einem KI-Modell sein können. Die Autoren legen besonderen Wert auf die Vermittlung der Erkenntnis, dass die Parameter die Rüstzeit beeinflussen und ihre Werte diese in positiver oder negativer Weise beeinflussen können.

Hierdurch kann generell unternehmensweit ein neues Prozessverständnis entwickelt werden, dass für Optimierungen genutzt

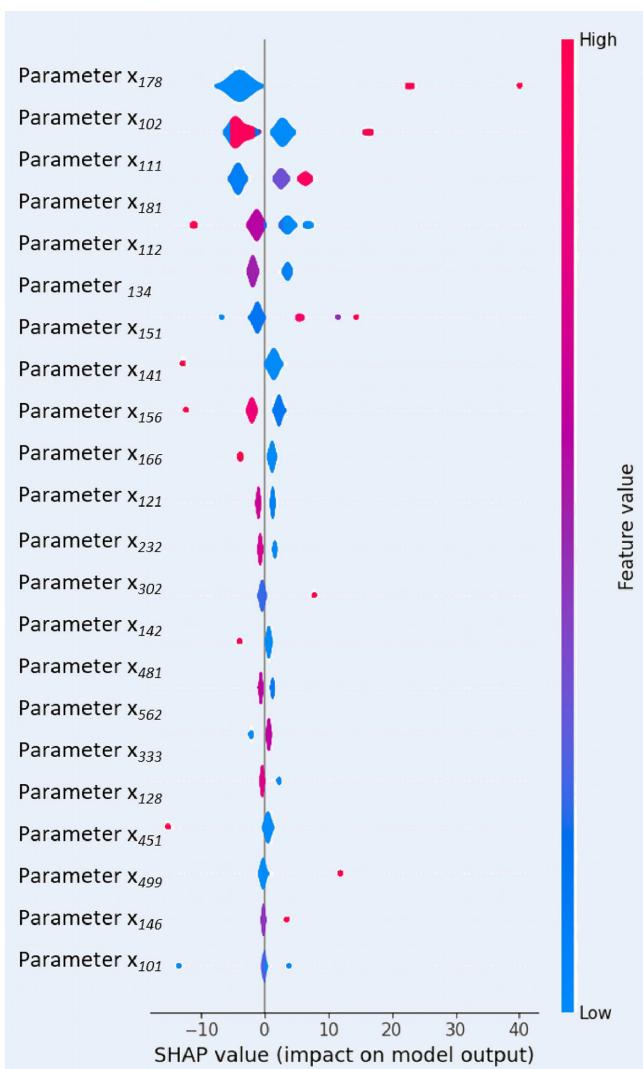


Bild 4. Gesamtbedeutung der Parameter und Verteilung der SHAP-Werte.
Grafik: ESB Business School, Reutlingen University

werden kann. **Bild 4** zeigt die Verteilung der Werte des jeweiligen Parameters, den Einfluss auf die Rüstzeit sowie ob höhere oder niedrige Werte positive oder negative Einflüsse erzeugen. Solche Musterzusammenhänge können in Schulungen, in der Ausbildung, in Shopfloor Meetings oder auch bei Qualitätsproblemen unterstützen.

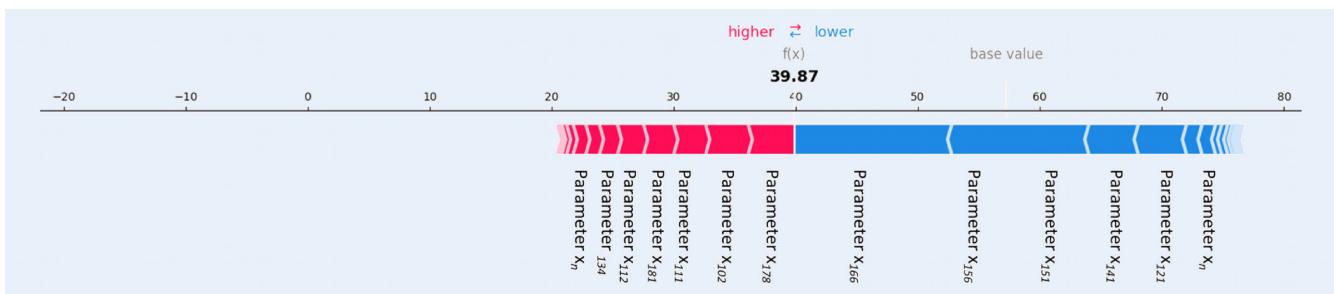


Bild 5. Beispiel für eine Vorhersage der Rüstzeit an Maschine 1. Grafik: ESB Business School, Reutlingen University

5.2 Prognose von Rüstzeiten anhand Produktionskombinationen

Es ist geplant, dass der Arbeiter die Vorhersage für die Rüstzeit für die nächste Produktionsart für alle verfügbaren Maschinen angezeigt bekommt. Die angezeigte Vorhersage ist in Bild 5 für eine Maschine dargestellt.

Der Werker bekommt diese Vorhersage beispielsweise für vier verfügbare Maschinen angezeigt. Er kann dann frei wählen, an welcher Maschine er rüsten möchte. Durch die angezeigte Vorhersagezeit sowie die Parameter erhält er entscheidende Informationen, warum eine Maschine besser geeignet ist als die andere. Zum Beispiel kann der Parameter x_{166} die Matrize sein, die bereits in der Maschine montiert ist. Wenn das folgende Produkt mit der gleichen Matrize hergestellt werden kann, kann der Arbeiter 11 normalisierte Minuten für das Einrichten einsparen. Bei anderen Maschinen müsste er zum Beispiel die Matrize wechseln.

Das Entscheidungsmodell sagt eine normalisierte Rüstzeit von 39,87 Minuten voraus. Durch die Visualisierung wird deutlich, welche Parameter die Rüstzeit sowohl positiv als auch negativ beeinflussen. Zum Beispiel liegt der Mittelwert der Rüstzeit aus der Datenverteilung bei 58 Minuten. Der Basiswert. Der Parameter x_{166} reduziert die Rüstzeit um 11 Minuten. Andere Parameter wie x_{178} erhöhen die Rüstzeit.

6 Zusammenfassung und Ausblick

In diesem Beitrag wird ein innovatives KI-Modell vorgestellt, das darauf abzielt, die Rüstzeiten in der CNC-Werkzeugherstellung zu reduzieren. Durch die Analyse von Produktionskombinationen identifiziert das Modell spezifische Muster, die zu langen Rüstzeiten beitragen, und nutzt diese Erkenntnisse, um effiziente Rüststrategien zu entwickeln. Dadurch wird eine Reduktion der Rüstzeiten erreicht, was zu einer Steigerung der Produktionsleistung und einer Reduzierung der Kosten führt.

Das KI-Modell ermöglicht eine Verringerung der Rüstzeiten um etwa 6 %, was zu einer Steigerung der Produktivität und einer Senkung der Betriebskosten führt. Allein durch diese Reduktion können im Jahr betrachtet voraussichtlich 11500 zusätzliche Rüstvorgänge durchgeführt werden aufgrund der dadurch zusätzlich zur Verfügung stehenden Zeit. Die verbesserte Vorhersagegenauigkeit des Algorithmus optimiert die Produktionsplanung und -steuerung und ermöglicht eine höhere Flexibilität sowie eine bessere Anpassung an die Kundenbedürfnisse. Wenn die zusätzlich zu Verfügung stehende Zeit genutzt werden kann, um Produkte zu produzieren, gehen wir von einem zusätzlichen Mehrumsatz bei gleichbleibenden Fixkosten im 6-stelligen Bereich bei nur einer Arbeitsplatzgruppe aus.

Die positiven Ergebnisse unterstreichen das Potenzial erkläbarer KI in der CNC-Werkzeugherstellung zur Rüstzeitoptimierung. Zukünftige Forschungen sollten die Genauigkeit von KI-Prognosen verbessern, die Integration in Planungssysteme vorantreiben und benutzerfreundliche Schnittstellen entwickeln, um KI-Entscheidungen verständlicher zu machen.

Der Beitrag präsentiert ein Entscheidungsmodell, das auf Datenanalyse basiert, um Rüstzeiten in der Produktion zu reduzieren. Das Modell zeichnet sich durch seine Fähigkeit aus, komplexe und nichtlineare Produktionsdaten zu verarbeiten und bietet gleichzeitig Transparenz über die Bedeutung verschiedener Parameter. Dies ermöglicht es Herstellern, Prioritäten für Prozessoptimierungen zu setzen, was zu Rüstzeitverbesserungen führen kann.

Das Modell hat Grenzen, da es auf Korrelationen aufbaut, die ohne klare Kausalität zu Fehlinterpretationen führen können. Zudem sind Erklärungsmethoden nachträglich angreifbar, was die Wichtigkeit der Einbeziehung von Experten in den Entwicklungsprozess unterstreicht, um solche Schwachstellen zu adressieren.

Das vorgestellte Entscheidungsmodell ermöglicht eine effiziente Integration in die Produktionsplanung und liefert neue Einsichten aus bestehenden Daten. Es ist generisch gestaltet, benötigt lediglich Produktionsparameter und reduziert Rüstzeiten durch optimierte Produktionskombinationen. Die Wirksamkeit dieses Ansatzes wird durch die Kombination aus nichtlinearer Modellierung und SHAP-Werten aus dem Bereich der erklärbaren KI bestätigt. Das Design des Modells verspricht breite Anwendbarkeit in datenreichen Fertigungsumgebungen und eröffnet neue Möglichkeiten für den Einsatz von erklärbarer KI in Produktionsplanung und -steuerung.

L iteratur

- [1] Bauer, M.; van Dinther, C.; Kiefer, D.: Machine learning in SME. An empirical study on enablers and success factors. A vision for the future 1 (2021) 5
- [2] Hundal, S.; Kostyuk, A.; Govorun, D. (Hrsg.): Corporate governance: A search for emerging trends in the pandemic times. Corporate governance: A search for emerging trends in the pandemic times, May 13-14, 2021. Virtus Interpress 2021 2021
- [3] Braakmann, N.; Wagner, J.: Product Diversification and Profitability in German Manufacturing Firms. In: Malchin, A.; Voshage, R.; Wagner, J. (Hrsg.): Empirical Studies with New German Firm Level Data from Official Statistics. De Gruyter 2011, S. 326–335
- [4] Tsai, C.-W.; Lai, C.-F.; Chao, H.-C. et al.: Big data analytics: a survey. Journal of Big Data 2 (2015) 1
- [5] Ma, T.; Zhang, A.: AffinityNet: Semi-Supervised Few-Shot Learning for Disease Type Prediction. Proceedings of the AAAI Conference on Artificial Intelligence 33 (2019) 01, S. 1069–1076
- [6] Zennaro, I.; Finco, S.; Battini, D. et al.: Big size highly customised product manufacturing systems: a literature review and future research

- agenda. International Journal of Production Research 57 (2019) 15–16, S. 5362–5385
- [7] Ulrich, P.; Frank, V.; Kratt, M.: Adoption of artificial intelligence technologies in German SMEs – Results from an empirical study. Corporate governance: A search for emerging trends in the pandemic times, 2021, S. 76–84
- [8] Mourtzis, D.; Doukas, M.: The Evolution of Manufacturing Systems. In: Wang, J.; Modrák, V.; Semančo, P. (Hrsg.): Handbook of Research on Design and Management of Lean Production Systems. IGI Global 2014, S. 1–29
- [9] Jamal, A.; Sarker, B. R.; Mondal, S.: Optimal manufacturing batch size with rework process at a single-stage production system. Computers & Industrial Engineering 47 (2004) 1, S. 77–89
- [10] Hopp, W. J.; Spearman, M. L.: Factory physics. Long Grove, Ill.: Wave-land Press, Inc 2011
- [11] Suri, R.: Quick response manufacturing. A companywide approach to reducing lead times. Portland, Or.: Productivity Press 1998
- [12] Lodree, E. J.; Geiger, C. D.; Jiang, X.: Taxonomy for integrating scheduling theory and human factors: Review and research opportunities. International Journal of Industrial Ergonomics 39 (2009) 1, S. 39–51
- [13] Ribeiro, M. T.; Singh, S.; Guestrin, C.: „Why Should I Trust You?“ KDD ’16: The 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco California USA, 2016, S. 1135–1144
- [14] Doshi-Velez, F.; Kim, B.: Towards A Rigorous Science of Interpretable Machine Learning, 2017
- [15] Witten, I. H.; Frank, E.; Hall, M. A.: Data Mining: Practical Machine Learning Tools and Techniques. Elsevier 2011
- [16] Cui, R.; Gallino, S.; Moreno, A. et al.: The Operational Value of Social Media Information. Production and Operations Management 27 (2018) 10, S. 1749–1769
- [17] Guidotti, R.; Monreale, A.; Ruggieri, S. et al.: A Survey of Methods for Explaining Black Box Models. ACM Computing Surveys 51 (2019) 5, S. 1–42
- [18] Guyon, I.; Weston, J.; Barnhill, S. et al.: Gene Selection for Cancer Classification using Support Vector Machines. Machine Learning 46 (2002) 1/3, S. 389–422
- [19] Breiman, L.: Random forests. Machine Learning 45 (2001) 1, S. 5–32
- [20] Friedman, J. H.: Greedy Function Approximation: A Gradient Boosting Machine. The Annals of Statistics 29 (2001) 5, S. 1189–1232
- [21] Lundberg, S.M., & Lee, S.: A Unified Approach to Interpreting Model Predictions. Neural Information Processing Systems (NIPS), 2017
- [22] Groover, M. P.: Fundamentals of modern manufacturing. Materials, processes, and systems. Singapore: John Wiley & Sons Singapore Pte Ltd 2021
- [23] Cakmakci, M.: Process improvement: performance analysis of the setup time reduction-SMED in the automobile industry. The International Journal of Advanced Manufacturing Technology 41 (2009) 1–2, S. 168–179
- [24] Nakajima, S.: Introduction to TPM. Total productive maintenance. Cambridge Mass.: Productivity Press 1988
- [25] Ángel-Bello, F.; Álvarez, A.; Pacheco, J. et al.: A heuristic approach for a scheduling problem with periodic maintenance and sequence-dependent setup times. Computers & Mathematics with Applications 61 (2011) 4, S. 797–808
- [26] Chen, T.; Guestrin, C.: XGBoost. KDD ’16: The 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco California USA, 2016, S. 785–794
- [27] Sun, J.; Zhang, D.; Hu, H. et al.: Predicting Human Discretion to Adjust Algorithmic Prescription: A Large-Scale Field Experiment in Warehouse Operations. SSRN Electronic Journal (2019)

**Daniel Kiefer, M. Sc.**

Foto: Autor

daniel.kiefer@reutlingen-university.de

Tel. +49 7121 2711060

Florian Grimm, M. Sc.

florian.grimmm@reutlingen-university.de

Prof. Dr. Tim Straub

tim.straub@reutlingen-university.de

Prof. Dr. Günter Bitsch

günter.bitsch@reutlingen-university.de

ESB Business School, Reutlingen University
Alteburgstr. 150, 72762 Reutlingen
www.esb-business-school.de**Jacqueline Höllig**

hoellig@fzi.de

Tel. +49 721 9654-657

FZI Forschungszentrum Informatik
Haid-und-Neu-Str. 10–14, 76131 Karlsruhe
www.fzi.de**Clemens Van Dintherr**

c.v.dintherr@gmx.de

Tel. +49 721 608-48370

Institute of Information Systems and Marketing (IISM)
Kaiserstr. 89-93, 76133 Karlsruhe**LIZENZ**

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