



Adaptive Prüfung in der Variantenproduktion

Durch App-basierte Prüfplanung Aufwände reduzieren

Bei der adaptiven Prüfplanung werden Prüfergebnisse und die sich ständig ändernde Produktionsumgebung kontinuierlich analysiert und Analyseergebnisse in die Prüfplanung rückgeführt. Die Analyse basiert auf datengetriebenen Ansätzen, wie statistischen Auswertungen und Machine-Learning-Verfahren. Letztere bieten das Potenzial, Zusammenhänge aufwandsarm zu detektieren und für den Anwender nutzbar zu machen

Meike Huber, Jonathan S. Greipel, Robert H. Schmitt

Um im Wettbewerb zu bestehen, stimmen KMU ihre Produkte zunehmend individuell auf Kundenanforderungen ab und gehen in eine Variantenproduktion über. In der Variantenproduktion ist eine 100%-Prüfung aller Merkmale üblich, welche mit einem hohen Prüfaufwand verbunden ist. [1] In der Großserienproduktion wird häufig eine Stichprobenprüfung von Schlüsselmerkmalen

eingesetzt [2]. Dies ist bei der Variantenproduktion aufgrund der geringen Losgrößen nicht möglich. Zudem fehlt KMU ein Leitfaden zur Prüfplanung, da die VDI-Richtlinie 2619 zurückgezogen wurde. Aktuell wird die VDI-Richtlinie 2600-3 „Adaptive Prüfplanung“ erstellt. Bei der adaptiven Prüfplanung werden Prüfergebnisse und die sich ständig ändernde Produktionsumgebung kontinuierlich analysiert und Analyseer-

gebnisse in die Prüfplanung rückgeführt [1, 3]. Die Analyse basiert auf datengetriebenen Ansätzen, wie statistischen Auswertungen und Machine-Learning-Verfahren. Letztere bieten das Potenzial, Zusammenhänge aufwandsarm zu detektieren und für den Anwender nutzbar zu machen [4].

In diesem Artikel wird ein Verfahren beschrieben, das Methoden aus dem Bereich des Machine Learning nutzt, um KMU für

eine adaptive Prüfplanung in der Variantenproduktion zu befähigen. Das Verfahren umfasst die Prozess- und Zielanalyse, die Schlüsselmerkmalsdefinition, die Mischlosbildung und die Adaption des Prüfplans (Bild 1).

Analyse der Rahmenbedingungen

Die Analyse der Rahmenbedingungen ist Voraussetzung für die Umsetzung der adaptiven Prüfplanung. Nur wenn im Vorfeld die notwendigen Zielvorgaben (Risiko, Kosten, Zeit, Qualität) definiert wurden, können Prüfpläne kosten- und nutzenoptimal angepasst werden. Die verfügbaren Prozessinformationen müssen im Vorfeld analysiert werden, um passende Algorithmen für die vorliegenden Daten zu identifizieren und eine automatisierte Auswertung zu ermöglichen. Basierend auf den Analyseergebnissen, erfolgt die Definition von Schlüsselmerkmalen, Mischlosen und Stichprobenumfängen.

Schlüsselmerkmalsdefinition

Ziel der Schlüsselmerkmalsdefinition ist die Identifikation einer Minimalanzahl an Prüfmerkmalen, bei Beibehaltung einer hinreichend genauen Bestimmung der Bauteilqualität [2]. Das Verfahren umfasst die Gruppierung redundanter und die Identifikation relevanter Merkmale. Zur Gruppierung redundanter Merkmale eignen sich Cluster-Algorithmen aus dem Bereich des „Unsupervised Learning“, da hiermit Klassen ähnlicher Merkmale identifiziert werden können, ohne dass die Klassen im Vorfeld definiert werden. Die Gruppierung kann beispielsweise mit Hilfe einer Principal Feature Analysis oder mittels Autoencoder erfolgen. Um relevante Merkmale zu identifizieren, werden Feature-Selection-Methoden aus dem Bereich des „Supervised Learning“ genutzt. Hiermit können relevante Merkmale aufwandsarm und zuverlässig aus einer Gruppe ähnlicher Merkmale identifiziert werden. Die Methoden basieren zum Beispiel auf dem Informationsgehalt oder der Prozessfähigkeit. Zur Bewertung der besten Algorithmen werden Kennzahlen (Accuracy, Specificity, Sensitivity) eingesetzt. Um den Kosten-Nutzen-Faktor der reduzierten Prüfung abzuschätzen, wird der Anteil der Schlüsselmerkmale (in %) ermittelt. In Abhängigkeit der definierten Zielvorgaben wird der pas-

sende Algorithmus und damit eine Menge an Schlüsselmerkmalen ausgewählt.

Mischlosbildung

Da die klassische Stichprobenprüfung in der Variantenproduktion aufgrund der kleinen Losgrößen nicht angewandt werden kann, werden die Varianten zu homogenen Mischlosen gruppiert. Durch die Mischlosbildung erhöht sich die Losgröße und die Entnahme von Stichproben ist statistisch begründbar. Zur Mischlosdefinition können Verfahren zum Pooling von Daten, die Clusteranalyse und das Expectation-Maximization-Verfahren genutzt werden. Die Algorithmen werden anhand der Inhomogenität der Mischlose bewertet: je mehr Varianten gruppiert werden, umso höher ist das Risiko, inhomogene Mischlose zu bilden. Zur Quantifizierung des Risikos wird das Bayes Informationskriterium genutzt (BIC). Wie bei der Schlüsselmerkmalsdefinition wird diejenige Mischlosgruppierung gewählt, welche den zuvor definierten Zielvorgaben genügt.

Risikobewertung und Entwicklung des Stichprobenprüfplans

Auf Basis der Schlüsselmerkmals- und Mischlosdefinition wird ein Prüfplan aufgestellt. Hierzu werden die gebildeten Mischlose sowie die identifizierten Schlüsselmerkmale zusammengefasst. Für jedes zu prüfende Merkmal wird ein Stichprobenumfang festgelegt. Zur Bestimmung der Stichprobenumfänge müssen durch den Anwender im Vorfeld das Acceptable Quality Level (AQL), das Rejectable Quality Level (RQL), das Produzentenrisiko (α) und das Konsumentenrisiko (β) festgelegt werden. In Abhängigkeit von der Verteilung der Merkmale und unter Verwendung statistischer Methoden werden die Stichprobenumfänge und das Risiko gegenüber einer 100%-Prüfung aller Merkmale ermittelt. Sind die Gesamtrisiken größer, als der vom Anwender festgelegte Wert, erfolgt eine adaptive Anpassung des Stichprobenprüfplans.

Zusammenführung der Methoden innerhalb einer App

Um das Verfahren für den Anwender nutzbar zu machen, wurde eine lizenzfreie App (s. Abbildung 2) in der Programmiersprache Rentwickelt. Die App ist in vier Schritte »

INFORMATION & SERVICE

AUTOREN

Meike Huber, M.Sc. ist wissenschaftliche Mitarbeiterin am Lehrstuhl für Fertigungsmesstechnik und Qualitätsmanagement des WZL Werkzeugmaschinenlabor der RWTH Aachen University.

Jonathan S. Greipel, M.Sc. war bis 2020 als Gruppenleiter am Lehrstuhl für Fertigungsmesstechnik und Qualitätsmanagement des WZL Werkzeugmaschinenlabor der RWTH Aachen University beschäftigt.

Prof. Dr.-Ing. Robert H. Schmitt ist Inhaber des Lehrstuhls für Fertigungsmesstechnik und Qualitätsmanagement am WZL Werkzeugmaschinenlabor der RWTH Aachen University.

LITERATURHINWEISE

- Greipel, J. S., Ortiz Sarceño, D., and Schmitt, R. H. Adaptive Prüfplanung für Kleinserien. Automatisierbare Methodik zur Erstellung eines adaptiven Stichproben-Prüfplans für Kleinserien. *wt Werkstattstechnik online* 2017, 107(11), 780–785.
- Lee, D. J. and Thornton, A. C. 08181996. The Identification and Use of Key Characteristics in the Product Development Process. In *Volume 4: 8th International Conference on Design Theory and Methodology*. American Society of Mechanical Engineers. DOI=10.1115/96-DETC/DTM-1506.
- Schmitt, R. and Kukulies, J. 2016. *Leitfaden zur Gestaltung eines ganzheitlichen Prüfplanung. Anwender-Leitfaden und CD-ROM*. FQS-DGQ-Band 84–10. FQS – Forschungsgemeinschaft Qualität e.V., Frankfurt am Main.
- Journal of Machine Learning Research*.

FÖRDERHINWEIS

Das IGF-Vorhaben „APProVe – App-basierte Aufwandsreduzierung bei der adaptiven Prüfung in der Produktion von Varianten“ (20618 N) der Forschungsvereinigung Forschungsgemeinschaft Qualität e. V. (FQS), August-Schanz-Straße 21A, 60433 Frankfurt am Main wurde über die AiF im Rahmen des Programms zur Förderung der Industriellen Gemeinschaftsforschung (IGF) vom Bundesministerium für Wirtschaft und Energie aufgrund eines Beschlusses des Deutschen Bundestages gefördert. Der Schlussbericht ist auf Anfrage bei der FQS Forschungsgemeinschaft Qualität e. V. erhältlich.

KONTAKT

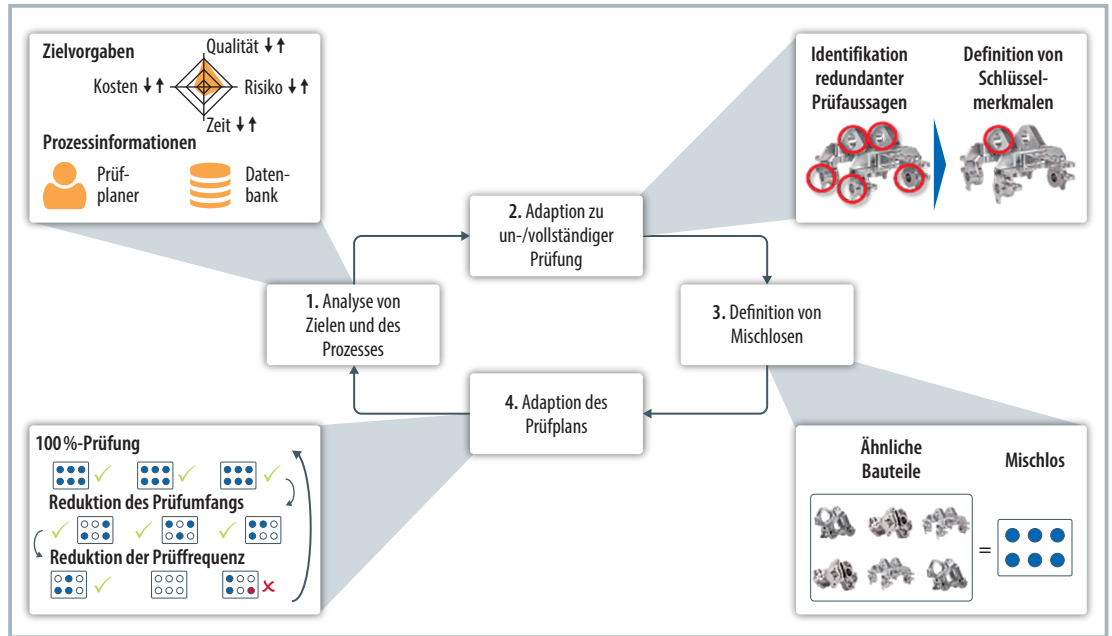
Meike Huber
T 0241 80 26946
m.huber@wzl.rwth-aachen.de

Bild 1. Regelkreis für die adaptive Prüfplanung mittels Algorithmen –Bildquelle der Bauteilabbildungen:

Quelle:

Lauscher Präzisionstechnik GmbH

© Hanser



aufgeteilt, durch die der Nutzer geführt wird (Datenaufbereitung, Schlüsselmerkmalsdefinition, Mischlosbildung, Stichprobenprüfplanung mit Risikoangabe). Der Nutzer kann die Auswertungen automatisiert durchführen. Zudem besteht die Möglichkeit, händische Anpassungen vorzunehmen. So können beispielsweise einzelne Merkmale, die aufgrund von Kundenanforderungen geprüft werden müssen, in den Prüfplan aufgenommen werden, auch wenn die Algorithmen diese Merkmale nicht als zu prüfende Merkmale identifiziert haben. Weiter besteht die Möglichkeit, einen Report zur Dokumentation zu erstellen.

Validierung des Verfahrens

Zur Validierung der einzelnen Schritte wurde mit künstlichen Datensätzen und Real-

daten geprüft, ob die Algorithmen im Sachzusammenhang sinnvolle Ergebnisse liefern. In einer Testphase innerhalb mehrerer KMU wurde die gesamte App umfassend validiert. Hier wurde die Plausibilität der Entscheidungen der Algorithmen zur Schlüsselmerkmalsdefinition und Mischlosbildung geprüft. Zudem wurde abgeschätzt, inwieweit sich der Aufwand gegenüber einer 100%-Prüfung aller Merkmale reduziert. Anhand der bereitgestellten Daten konnte bestätigt werden, dass die App plausible Ergebnisse liefert. Im Rahmen einer Analyse der Prüfdaten eines Automobilteilerzulieferanten konnte beispielsweise eine theoretische Reduzierung der Anzahl der durchzuführenden Prüfungen um bis zu 90% ermöglicht werden.

Zusammenfassung

In der Variantenproduktion erfolgt eine 100%-Prüfung aller Merkmale, da die Losgrößen für eine Stichprobenprüfung nicht ausreichen. Insbesondere für KMU bedeutet dies eine hohe wirtschaftliche Belastung, da die Prüfungen viele Ressourcen binden. In diesem Artikel wurde ein Verfahren beschrieben, mit Hilfe dessen eine Reduzierung des Prüfumfanges in der Variantenproduktion ermöglicht wird. Das Verfahren nutzt Methoden aus dem Bereich des Machine Learning und kann ohne Einsatz von Fachwissen genutzt werden. Zur einfachen Anwendung wurde eine lizenzfreie App entwickelt, welche in unterschiedlichen Unternehmen erprobt wurde. Die Anwendung des Verfahrens in der Praxis zeigt, dass eine Reduzierung der Prüfungen um bis zu 90% möglich ist, ohne dass relevante Informationen verloren geht. ■

	keep_delete	clust	pairwise	statClust	devClust	EMC	majority
V1	1	1	1	1	1	1	1
V2	1	1	1	2	1	1	1
V3	2	2	1	2	2	2	2

Bild 2. Auszug der entwickelten App für den Einsatz in der adaptiven Prüfplanung. Hier: Ansicht bei der Mischlosbildung. Quelle: WZL RWTH Aachen