



KI optimiert Fahrzeugqualität

Predictive Testing unterstützt die Autoindustrie auf Basis von Deep Learning

Im Zeitalter von Industrie 4.0 und dem Einzug der Künstlichen Intelligenz (KI) in nahezu alle Lebens- und Fachbereiche geht es im Qualitätsmanagement derzeit auch um die Frage, wie maschinelle Lernverfahren auf Produktionsdaten angewendet werden können, um Vorhersagen über zukünftige qualitätsrelevante Ereignisse zu treffen. Die BMW Group hat daher in Zusammenarbeit mit dem Fachgebiet Qualitäts- und Prozessmanagement der Universität Kassel das Konzept Predictive Testing entwickelt, um die Produktqualität bei der Produktion von Fahrzeugen durch den Einsatz von Deep Learning auf ein neues Level zu heben.

Andreas Schoch und Robert Refflinghaus

Primäres Ziel deutscher Automobilhersteller ist die konsequente Erfüllung eines hohen Qualitätsversprechens der Hersteller an ihre Kunden. Dafür werden an definierten Punkten in der Produktion Qualitätsprüfungen durchgeführt. Qualitätsprüfungen sind ein wichtiger Befähiger zur Sicherstellung einer hohen Pro-

duktqualität und damit integraler Bestandteil von „Null-Fehler-Strategien“ in der Produktion. Dabei stellen insbesondere Mitarbeiterprüfungen, bei denen ein Mitarbeiter das Fahrzeug einer Qualitätsprüfung unterzieht, eine geeignete Möglichkeit dar, das Fahrzeug aus Kundensicht zu prüfen. Eine klassische Mitarbeiterprüfung ist zum Bei-

spiel die Fahrt mit dem Fahrzeug über eine Rüttelstrecke, um auffällige Geräusche an einem Fahrzeug zu detektieren. Mitarbeiterprüfungen tragen durch ihre Fähigkeit, schwer zu identifizierende Mängel am Fahrzeug zu entdecken, maßgeblich zur Sicherstellung einer hohen Produktqualität bei.

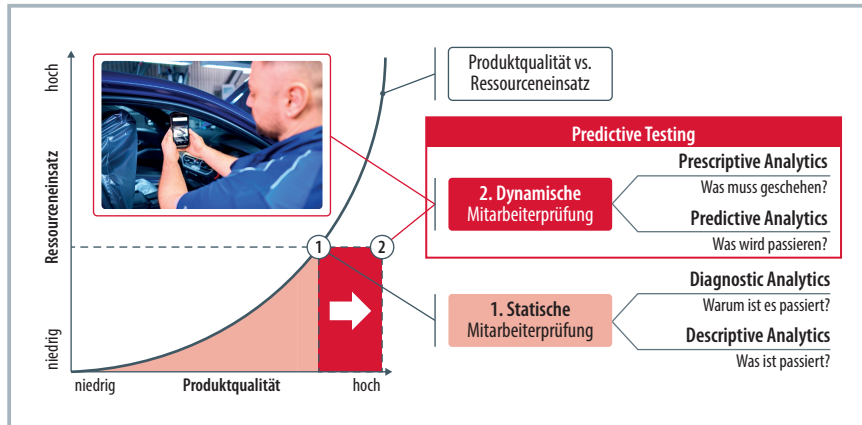


Bild 1. Predictive Testing zur Optimierung der Produktqualität bei gleichbleibendem Ressourceneinsatz durch dynamische Mitarbeiterprüfungen. Quelle: BMW Group © Hanser

Problemstellung

Aktuell sind vor allem statische Mitarbeiterprüfungen im Einsatz. Statische Mitarbeiterprüfungen bestehen aus Prüfinhalten, die sich aus der Fahrzeugarchitektur ableiten. Sie sorgen beispielsweise dafür, dass kundenrelevante Fahrzeugfunktionen zu 100 Prozent abgesichert sind. Die im Vorfeld definierten statischen Prüfinhalte von Mitarbeiterprüfungen werden punktuell durch reaktive Prüfinhalte ergänzt, die sich aus der aktuellen Fehlerlandschaft in der Produktion ableiten. Die reaktiven Prüfinhalte bewirken, dass in der Vergangenheit identifizierte Fehlerbilder gezielt abgesichert werden.

Zur Konzeption von statischen Mitarbeiterprüfungen werden in erster Linie deskriptive und diagnostische Analytics-Verfahren eingesetzt. Beide Analytics-Verfahren besitzen einen reaktiven Charakter, da sie Fehlerbilder analysieren, nachdem sie bereits eingetreten sind. Gute Beispiele dafür sind die traditionellen Fehleranalysen

(Fehlersammelkarten, Fehler-Prozess-Matrix (FPM), Ishikawa-Diagramme), bei denen bereits geschehene Ereignisse analysiert werden.

Herkömmliche Mitarbeiterprüfungen basieren auf deterministischen Planungsverfahren, um generische Prüfabläufe zu entwickeln, die für einen definierten Zeitraum Gültigkeit besitzen. Aufgrund der fehlenden Berücksichtigung von aktuellen Produktionsdaten über ein Fahrzeug besitzen herkömmliche Mitarbeiterprüfungen einen geringen Grad an Individualisierung. Aus der mangelnden Individualität folgt, dass sie in ihrer Fähigkeit, Fehlerbilder effizient zu detektieren, limitiert sind.

Ansatz

Aus diesem Grund stellt sich die Frage, ob die Anwendung von KI auf Produktionsdaten eine geeignete Möglichkeit darstellt, Fahrzeug-individuelle Mitarbeiterprüfungen zu entwickeln. Ziel der Dynamisierung

von Mitarbeiterprüfungen ist es, mehr Fehler bei gleichbleibendem Prüfaufwand zu finden. Dadurch verbessert sich die Effizienz von dynamischen im Vergleich zu statischen Mitarbeiterprüfungen, was mit einer direkten Optimierung der Produktqualität gleichzusetzen ist.

Die Effizienz von Mitarbeiterprüfungen ergibt sich aus der Anzahl fehlerhafter Fahrzeuge, die im Zuge der Prüfung erkannt wurden, und der Summe aller Fahrzeuge, an der die Prüfung durchgeführt wurde. Die Effizienz einer Mitarbeiterprüfung ist somit die Detektionsquote. Je mehr Fehler eine Mitarbeiterprüfung im Verhältnis zur geprüften Menge findet, desto effektiver ist sie. Bild 1 veranschaulicht den eben beschriebenen Ansatz zur Optimierung der Produktqualität (x-Achse) bei gleichbleibendem Ressourceneinsatz (y-Achse) durch den Einsatz dynamischer Mitarbeiterprüfungen. Darüber hinaus zeigt Bild 1 die beiden Arten von Mitarbeiterprüfungen und setzt sie in Beziehung zu den Ana- >>>

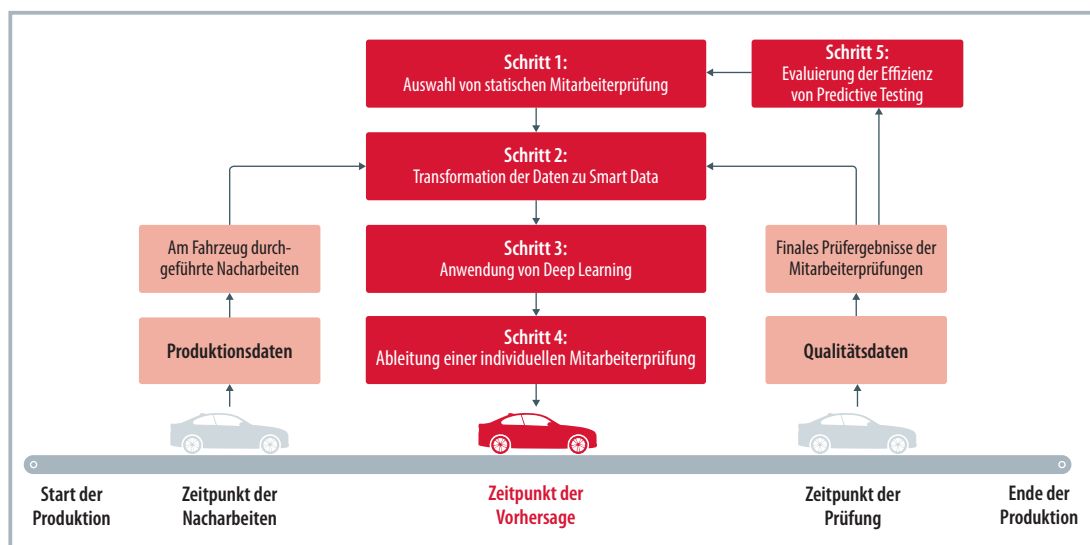


Bild 2. Predictive Testing basiert auf fünf Schritten und verfolgt das Ziel, die Effizienz von Mitarbeiterprüfungen durch den Einsatz von KI zu optimieren. Quelle: BMW Group © Hanser

lytics-Verfahren.

Predictive Testing ist ein von der BMW Group und dem Fachgebiet Qualitäts- und Prozessmanagement der Universität Kassel entwickeltes Konzept, um die Effizienz von Mitarbeiterprüfungen durch den Einsatz von KI gezielt zu optimieren. Predictive Testing basiert auf der Idee, Produktionsdaten eines Fahrzeugs zu nutzen, um eine Fahrzeug-individuelle Mitarbeiterprüfung zu generieren.

Dabei lernt im ersten Schritt ein tiefes neuronales Netz (Deep Learning) auf Basis historischer Daten den Zusammenhang zwischen den Produktions- und den Qualitätsdaten eines Fahrzeugs. Ein neuronales Netz eignet sich so beispielsweise das Wissen an, welche Nacharbeiten (Produktionsdaten) in der Vergangenheit zu welchen Ergebnissen in einer Mitarbeiterprüfung (Qualitätsdaten) geführt haben. Auf Basis des erlernten Beziehungswissens um die Zusammenhänge zwischen den Produktions- und den Qualitätsdaten empfiehlt das trainierte neuronale Netz für neue Fahrzeuge in der Produktion die Mitarbeiterprüfungen mit der höchsten Wahrscheinlichkeit, einen Fehler zu finden.

Eine trainierte KI könnte so zum Beispiel für ein Fahrzeug prognostizieren, ob eine Funktions-, eine Geräusch-, oder eine Sichtprüfung erfolgsversprechender ist. Bild 2 skizziert die benötigten Datenquellen sowie das schrittweise Vorgehen beim Einsatz von Predictive Testing in der Fahrzeugmontage der BMW Group.

Schritt 1: Auswahl von statischen Mitarbeiterprüfungen

Im vorliegenden Praxisbeispiel soll die Effizienz einer Geräuschprüfung in der Fahrzeugmontage der BMW Group optimiert werden. Bislang führt ein Mitarbeiter für alle Fahrzeuge diese Geräuschprüfung an einem definierten Takt in der Montage durch. Das entwickelte Konzept *Predictive Testing* wird nun dazu verwendet, die exklusive Geräuschprüfung in eine multiple, dynamische Mitarbeiterprüfung zu transformieren.

Anstatt der gegenwärtigen Geräuschprüfung findet in Zukunft also entweder eine Geräusch-, Funktions- oder eine Sichtprüfung statt. Die vorhandenen drei statischen Mitarbeiterprüfungen (Geräusch-, Funktions-, und Sichtprüfung) bilden somit

die Basis für die Gestaltung der neuen dynamischen Mitarbeiterprüfung. Fand ein Mitarbeiter während der Durchführung einer der drei bestehenden Mitarbeiterprüfungen ein oder mehrere Mängel am Fahrzeug, wird dies als positives Prüfergebnis gewertet, fand er hingegen keinen Mangel, wird dies als negatives Prüfergebnis festgehalten. Es existiert somit für jedes in der Vergangenheit produzierte Fahrzeug ein Nachweis darüber, ob ein Fehler im Zuge

spiegeln dadurch zu einem gewissen Teil die Qualität in der Herstellung eines Fahrzeugs wider, weswegen sie ein wertvoller Indikator zur Prädiktion von Ergebnissen in Mitarbeiterprüfungen sind.

Da eine Vielzahl unterschiedlicher Nacharbeiten existiert, werden als Input für das KI-Modell ausschließlich Nacharbeiten verwendet, die über einen gewissen Zeitraum mit einer gewissen Häufigkeit aufgetreten sind. So werden im vorliegenden Fall

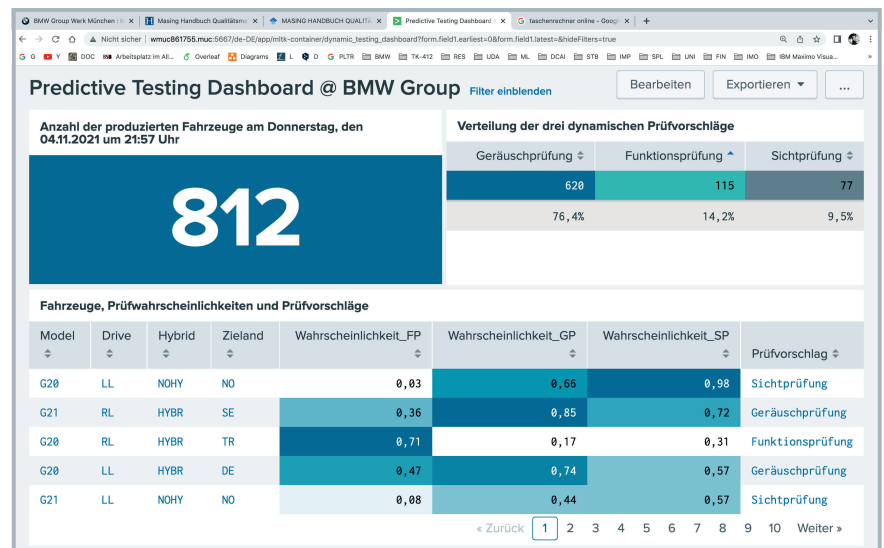


Bild 3. -Live Predictive Testing Dashboard in der Fahrzeugmontage der BMW Group. Quelle: BMW Group © Hanser

der Mitarbeiterprüfungen detektiert wurde oder nicht.

Schritt 2: Transformation von Daten zu Smart Data

Grundsätzlich stehen zwei Ansätze zur Optimierung der Leistungsfähigkeit von Machine Learning-Modellen zur Verfügung:

- die Verbesserung der Datenqualität und
- die Optimierung des Machine Learning-Modells.

Wie zahlreiche Studien belegen, hat eine Erhöhung der Datenqualität einen weitaus größeren Einfluss auf die Vorhersagegenauigkeit als die Hyperparameteroptimierung eines beliebigen Modells. Aus diesem Grund wird im zweiten Schritt die Datenqualität durch die Transformation von Rohdaten zu *Smart Data* gezielt verbessert, indem *Ausreißer* und *irrelevante Merkmale* aus den Nacharbeiten (Produktionsdaten) entfernt werden. Nacharbeiten sind von Mitarbeitern durchgeführte Tätigkeiten, die während der Produktion außerplanmäßig an einem Fahrzeug erfolgen. Nacharbeiten

ausschließlich Nacharbeiten verwendet, die in mindestens 1 % der Produktionsmenge und an mindestens einem Produktionstag in einer Woche aufgetreten sind. Darauf aufbauend werden aus der verbleibenden Menge der verfügbaren Nacharbeiten diejenigen aus dem Datensatz entfernt, die aufgrund ihres geringen Informationsgehalts keinen Mehrwert für das KI-Modell liefern.

Mitarbeiter, die vor Ort die Nacharbeiten an Fahrzeugen durchführen, haben ihr Wissen um die Bedeutung einzelner Nacharbeiten dazu genutzt, irrelevante Nacharbeiten wie beispielsweise „Barcode nicht lesbar“ aus dem Datensatz zu nehmen. Das Entfernen von Ausreißern und irrelevanten Nacharbeiten bewirkt eine Erhöhung der Datenqualität, die sich positiv auf die Lernbarkeit des Zusammenhangs auswirken kann.

Schritt 3: Anwendung von Deep Learning

Im Anschluss an die Optimierung der Datenqualität wird für jede der drei Mitarbeiterprüfungen ein eigenes neuronales Netz

trainiert, um den Zusammenhang zwischen den durchgeführten Nacharbeiten und den Mitarbeiterprüfungsergebnissen zu erlernen. Hierzu wurde ein Datensatz mit mehr als 200.000 Fahrzeugen im Verhältnis 80/20 in einen Trainings- und einen Testdatensatz geteilt. Für das Training des neuronalen Netzes wird der Trainingsdatensatz (80 %) verwendet und zur Evaluierung der Leistungsfähigkeit des Modells der Testdatensatz (20 %).

Zur Modellierung wird ein tiefes neuronales Netz (Deep Learning) der Open-Source-Bibliothek *TensorFlow* auf den Trainingsdatensatz angewendet. Die detaillierte Vorgehensweise und die zur Modellierung verwendete Netzarchitektur kann in der *TensorFlow*-Dokumentation „Classify structured data using Keras preprocessing layers“ im Detail nachgelesen werden.

Die Evaluierung des trainierten neuronalen Netzes auf dem Testdatensatz zeigt, dass sich die Ergebnisse der drei Mitarbeiterprüfungen mit einer Genauigkeit von über 95 % prognostizieren lassen. Neuronale Netze sind also in der Lage, auf Basis der an einem Fahrzeug durchgeführten Nacharbeiten zu prognostizieren, ob ein Fehler bei der Durchführung einer Mitarbeiterprüfung gefunden werden wird oder nicht.

Schritt 4: Ableitung einer individuellen Mitarbeiterprüfung

Nachdem die Lernbarkeit des Zusammenhangs im Rahmen der Modellierung nachgewiesen ist, wird das neuronale Netz zur Empfehlung von Mitarbeiterprüfungen in der Montage eingesetzt. Bild 3 zeigt das in der Produktion verwendete „Predictive Testing Dashboard“ am Beispiel eines Produktionstags der BMW Group im Werk München. So erfolgte beispielsweise am 4.11.2021 für 812 Fahrzeuge eine Fahrzeugindividuelle Mitarbeiterprüfung, wobei an 620 Fahrzeugen eine Geräuschprüfung, an 115 Fahrzeugen eine Funktionsprüfung und an 77 Fahrzeugen eine Sichtprüfung durchgeführt wurde.

Im unteren Teil des Dashboards ist die berechnete Wahrscheinlichkeit für einen positiven Befund in der Geräusch-, Funktions- und der Sichtprüfung tabellarisch aufgelistet. Die errechneten Wahrscheinlichkeiten bilden die Grundlage zur Entscheidung darüber, welche konkrete Mitarbei-

terprüfung am Fahrzeug durchgeführt werden soll. Die Tabelle zeigt, dass immer nur die Mitarbeiterprüfung mit der höchsten Wahrscheinlichkeit für einen positiven Befund am Fahrzeug durchgeführt wird.

Schritt 5: Evaluierung der Effizienz von Predictive Testing

Im letzten Schritt wird die Wirksamkeit des Konzepts evaluiert, indem die Detektionsquoten der statischen und der dynamischen Prüfstrategie miteinander verglichen werden.

Für einen Zeitraum von acht Wochen prüfte ein Mitarbeiter die Fahrzeuge mit der herkömmlichen statischen Prüfstrategie (nur Geräuschprüfung) und ein Mitarbeiter mit der neu entwickelten dynamischen Prüfstrategie (Geräusch-, Funktions-, oder Sichtprüfung). Der Vergleich der Detektionsraten ergab, dass die dynamische Prüfstrategie in Summe 23 % mehr Fehlerbilder bei gleichem Ressourceneinsatz im beobachteten Zeitraum detektierte als die statische Prüfstrategie. Die Anwendung von *Predictive Testing* führte also im vorliegenden Fall zu einer direkten Steigerung der Effizienz von Mitarbeiterprüfungen um 23 Prozent.

Ergebnis

Theoretisch betrachtet liefern neuronale Netze zwar gute Ergebnisse, haben aber den Nachteil, dass die Entscheidungen der Modelle nicht nachvollzogen werden können. Aus diesem Grund muss der Ansatz um weitere Algorithmen (z. B. Entscheidungsbäume) erweitert werden, um die Entscheidungsfindung plausibilisieren zu können.

Auf der praktischen Seite werden die Empfehlungen der KI bislang einzig dafür verwendet, eine der drei möglichen Mitarbeiterprüfungen zu favorisieren. In der nächsten Ausbaustufe soll die KI zur Gestaltung von kombinierten Mitarbeiterprüfungen verwendet werden, die sich aus verschiedenen Bestandteilen vorhandener Prüfungen zusammensetzen.

Der Einsatz von *Predictive Testing* in der Fahrzeugmontage der BMW Group zeigt, welch enormes Potenzial der Einsatz von datengetriebenen und dynamischen Prüfstrategien in der Produktion besitzt. Das entwickelte Konzept ist ein innovativer Ansatz, um die Produktqualität in der Fahrzeugmontage nachhaltig auf ein neues Level zu bringen. ■

**Fernstudium
Six Sigma Green Belt**
Kostengünstig und staatl.
geprüft. Beginn jederzeit!
FERNSCHULE WEBER
Tel. 0 44 87 / 263 - Abt: 168
www.fernschule-weber.de

INFORMATION & SERVICE

LITERATUR

- Nyce, C.: Predictive Analytics White Paper. In: American Institute for Chartered Property Casualty Underwriters/Insurance Institute of America, 2007
- Pfeifer, T.; Schmitt R.: Masing Handbuch Qualitätsmanagement. Carl Hanser Verlag, München 2021
- Ng A.: MLOps: From Model-centric to Data-centric AI, URL: <https://www.deeplearning.ai/wp-content/uploads/2021/06/MLOps-From-Model-centric-to-Data-centric-AI.pdf> (Stand: 8.8.2021)
- Tensorflow. Classify structured data using Keras preprocessing layers. https://www.tensorflow.org/tutorials/structured_data/preprocessing_layers

AUTOR

M.Sc. M.Sc. Andreas Schoch ist Doktorand bei der BMW Group und beschäftigt sich mit dem Einsatz von Künstlicher Intelligenz (insb. Deep Learning) zur Qualitäts- und Produktivitätsoptimierung in der Fertigung.
Prof. Dr.-Ing. Robert Refflinghaus leitet die Abteilung Qualitätsmanagement am RIF und das Fachgebiet Qualitäts- und Prozessmanagement an der Universität Kassel.

KONTAKT

Andreas Schoch
T 089 38230032
andreas.schoch@bmw.de