

Mit KI Fehler detektieren und ihre Ursachen identifizieren

Einen Fehler zu detektieren, ist gut – zusätzlich die Fehlerursache zu kennen, ist aber noch besser. Mit KI und Inline-Spray-Messtechnik lassen sich Lackierfehler mit sehr hoher Sicherheit in Echtzeit detektieren und sogar mit über 90%iger Sicherheit die dafür verantwortliche Fehlerquelle identifizieren. Der Beitrag ist die Fortsetzung eines Forschungsberichts, der in JOT 10/2023 erschienen ist.

Dr. Oliver Tiedje, Dr. Meiko Hecker

Das Fraunhofer IPA forscht gemeinsam mit den drei Unternehmen B + M Surface Systems, Helmut Fischer und AOM-Systems an der Optimierung des Lackierprozesses von Kunststoffteilen im Automobil- und Nutzfahrzeugbau mithilfe künstlicher Intelligenz (KI). In Ausgabe 10/23 von JOT – Journal für Oberflächentechnik wurden bereits erste Ergebnisse aus dem Forschungsprojekt veröffentlicht (Seite 56, 57). Damals wurde gezeigt, dass sich mit der Inline-Spray-Messtechnik durch die Kontrolle der relevanten Spray-Parameter, Prozessfehler

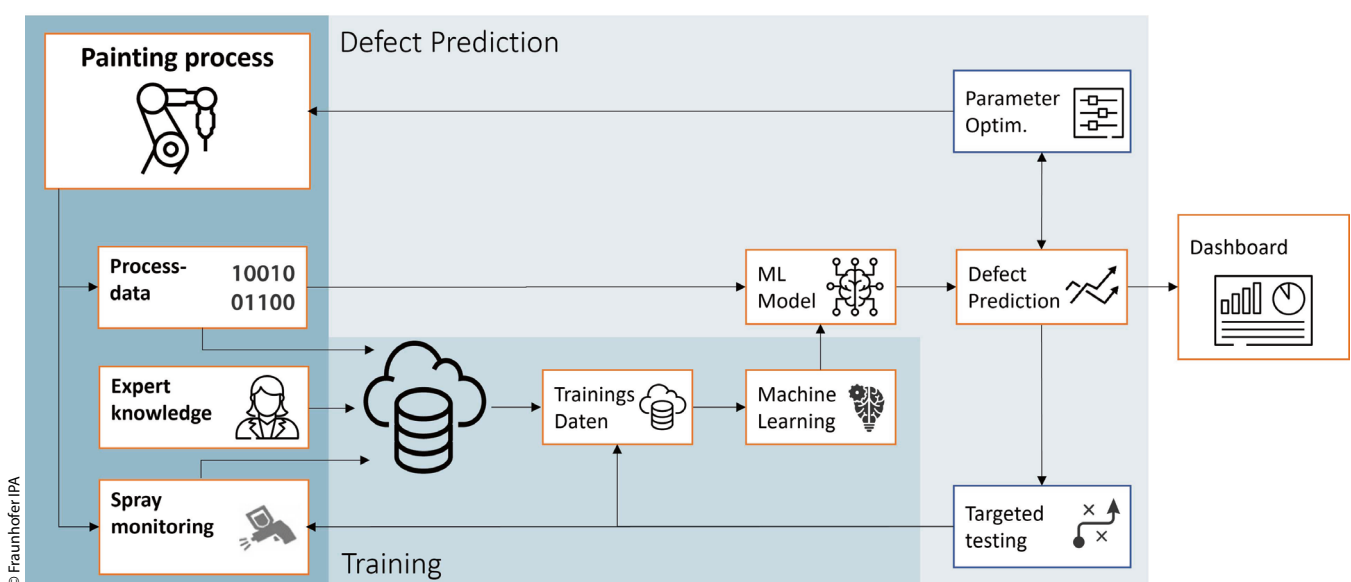
in der Beschichtung zuverlässig in Echtzeit detektieren lassen, noch bevor das Bauteil überhaupt fertig lackiert ist.

Etwas mehr als ein Jahr später soll nun über die neuesten Ergebnisse aus dem Forschungsprojekt berichtet werden. In dieser Zeit sind die Prozessdaten aus der Anlagensteuerung, die End-of-Line-Produktqualitätsdaten und die Qualitätsdaten des Sprühstrahls miteinander vernetzt worden. Zusätzlich sind diese vernetzten Daten mittels maschinellen Lernens verarbeitet worden. Dadurch ist es gelungen, neben der bereits


erfolgten Detektion der Prozessfehler auch die jeweilige Fehlerursache (zum Beispiel Düsen-Defekt) mit über 90%iger Sicherheit zu bestimmen. Auf der Basis dieser Ergebnisse kann der Werker nun eine zielgerichtete Maßnahme zur Fehlerbehebung durchführen, statt einer langwierigen Trial-and-Error-Fehlersuche.

Herausforderungen im Lackierprozess

Die Lackierung gilt bis heute als eine nicht durchgängig beherrschbare Pro-



Aufbau des Qualitätsregelkreises mittels Maschinellen Lernens.



© Fraunhofer IPA

Das System überwacht den Prozess am Hochrotationszerstäuber.

zessabfolge. Dies kann mit Anlagenausfällen, Ausschussteilen und mit Nacharbeit verbunden sein, weil zum Beispiel die vorgegebene Lackschichtdicke nicht überall eingehalten werden kann. Dabei sind verschiedene Herausforderungen zu meistern. Auf der einen Seite ist es die Wechselwirkung von Lackmaterial – abhängig vom Zulieferer –, Applikation und Verfahrenstechnik.

Auf der anderen Seite geht es sehr stark um die Daten. Grundsätzlich sind sie in den Lackieranlagen prinzipiell vorhanden, aber häufig gibt es folgende Probleme:

- Nur partielle Beschreibung der Prozesse durch die vorhandenen Daten
- Sehr hohes Datenaufkommen
- Qualitätsdaten nur manuell / visuell erfasst
- Lernen von Abweichungen schwierig, da seltene Ereignisse

- Daten meist nicht verknüpft / auf einer Datenbank verfügbar
- Korrelation von Prozess mit Qualität aktuell nicht möglich

Mit Algorithmen des maschinellen Lernens soll daher die Lackierung von Kunststoffteilen im Automobil- und Nutzfahrzeugbau effizienter gestaltet werden. Dazu sollen intelligente Algorithmen sämtliche Daten, die während des Lackierprozesses anfallen, auswerten und frühzeitig vor Fehlern warnen und die Fehlerursache bestimmen.

Überwachung des Spritzstrahls und der Schichtdicke

Neu an dem Ansatz ist, dass auch die Qualität des Spritzstrahls mittels Spray-Messtechnik in die Datenauswertung einbezogen wird und somit ein meist noch

nicht überwachter Faktor aufgenommen wird. Außerdem werden neben den visuellen Qualitätsbeurteilungen auch Schichtdicken mittels Terahertz-Messtechnologie überwacht. Dafür haben die Projektpartner folgende Schritte unternommen:

- Ergänzung der fehlenden Spray-Sensorik (Vermessung des Lacksprays)
- Automatisierung der wichtigsten End-of-Line-Qualitätsgröße (Schichtdicke mittels Terahertz-Technologie)
- Vernetzung aller Datenquellen
- Erzeugung fehlender Datensätze (Fehlersimulation) im Technikum
- Auswahl des erfolgreichsten Machine-Learning-Modells
- Nutzung selbstlernender Verhaltensmodelle zur Vernetzung von Prozess- und Qualitätsdaten

Das Forschungsprojekt bildet daher eine Klammer über die Prozessdaten der Anlage, die Prozessdaten des Spritzstrahls und den Qualitätsdaten des Produktes. Das Ziel ist es, eine Qualitätsprognose auf Basis von Prozessdaten, eine umfassende Prozessüberwachung und die Reduktion der Datenkomplexität zu erreichen, um eine Vorwärts- und Rückwärts-Analyse zu ermöglichen: Was sind die Folgen von Abweichungen? Was sind die Ursachen?

Praktische Versuche

Die Versuche wurden an einem 6-achsigen Lackierroboter durchgeführt, der mittels Hochrotationszerstäuber einen Metallic-Basislack aufbringt. Dabei wurden Standard-Betriebsparameter aus der Industrie gewählt. Zur Überwachung des Beschichtungsprozesses beziehungsweise des Sprühs wird ein SpraySpy, Typ ProcessLine PL200 der Firma AOM-Systems, genutzt. Das System überwacht die Qualität des Sprühstrahls während der Beschichtung und detektiert auch kleinste Abweichungen vom Sollwert. Dies können zum Beispiel Änderungen in der Sprühstrahlgeometrie/dem Sprühstrahlwinkel, des Volumenflusses oder der Viskosität des Lackes sein.

Für die erfolgreiche Klassifizierung der Fehlerart wurden verschiedene Fehlerszenarien simuliert und die dazugehörigen Prozessdaten erfasst und verarbeitet. Für die Fehler-Simulation wurden im Technikum das Material, das Equipment und die Prozessdaten manipuliert. Beispielsweise wurden vom Hersteller als fehlerhaft deklarierte Lenkluftringe und Glockenteller zur Fehlersimulation genutzt.

Projektübersicht

Titel: „Effizienzsteigerung von Lackierprozessen durch mehrschichtige Vernetzung von Prozess- und Qualitätsdaten mittels selbstlernender Verhaltensmodelle (pAInt-Behaviour)“

Gefördert durch: Bundesministerium für Bildung und Forschung

Projekträger: Projekträger Karlsruhe (PTKA) Produktion, Dienstleistung und Arbeit

Projektkonsortium:

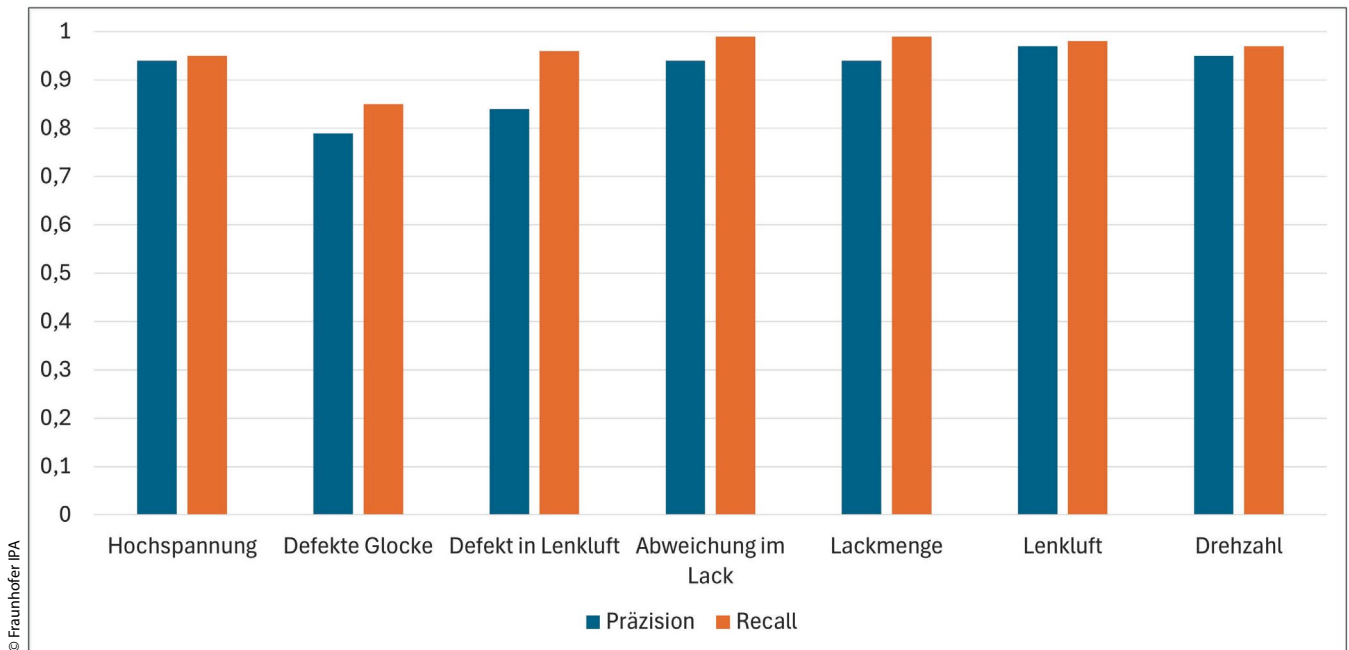
b+m surface systems GmbH

AOM-Systems GmbH

Helmut Fischer GmbH Institut für elektronische Messtechnik

Fraunhofer-Institut für Produktionstechnik und Automatisierung

Assoziiert: SMP Automotive GmbH



Darstellung der Güte des Random Forest Algorithmus für verschiedene Prozessabweichungen.

Ziel war es dabei, üblicherweise in der Produktion auftretende Fehler zu simulieren und deren charakteristische Fehlerbilder des Fehlerursprungs zu erhalten, um die KI darauf anzulernen.

Die parallel aufgezeichneten Eingangsdaten umfassen Anlagendaten wie den Materialdruck, die Prozess-/Spray-Qualitätsdaten sowie die Produktqualitätsdaten der Schichtdicke und des Farbtons. Die so gewonnenen Daten wurden mittels KI verarbeitet. Da es aber verschiedene KI-Algorithmen gibt, die zur Datenverarbeitung genutzt werden können und dies die Ergebnisqualität beeinflussen kann, ist die Auswahl eines geeigneten Algorithmus wichtig. Daher hat das Projektteam verschiedene KI-Methoden analysiert, um die geeignetste Methode für diese Anwendung zu bestimmen. Es wurden zum Beispiel folgende Algorithmen erprobt: Stochastic Gradient Decent, K-Nearest Neighbor, Gaussian Process Classifier, Gaussian Native Bayes, Random Forest, Gradient Boosting, et cetera. Für die hier gestellte Aufgabe erwies sich der „Random Forest“-Algorithmus als der erfolgreichste, weswegen dieser für die Auswertung der Ergebnisse genutzt wurde. Zur Bewertung von Algorithmen muss man die Prozessabweichungen, die übersehen wurden und die fälschlicherweise als Fehler angezeigten Events erfassen und gegenüberstellen.

Deshalb wurden die Algorithmen nach der Präzision P, das heißt dem Anteil der

zurecht erkannten Abweichungen an allen erkannten Abweichungen und nach dem Recall R, den zurecht erkannten Fehler an allen echten Abweichungen bewertet.

Mathematisch ausgedrückt:

$$\text{Falschmeldungen } F = 1 - P$$

$$\text{Nicht erkannte Fehler } N = 1 - R$$

Der Recall hingegen beschreibt die Güte der Fehlerzuordnung und liegt in den Versuchen immer über 90 % (Bild 3), außer für die defekte Glocke – dies liegt aber daran, dass die im Projekt verwendeten fehlerhaften Glocken nur insofern fehlerhaft waren, als das die Standzeit überschritten war und kein mechanischer Defekt vorlag. Daher ist davon auszugehen, dass die als fehlerhaft deklarierten Glocken noch sehr nah am i.O.-Zustand sind und es fraglich ist, ob diese fehlerhaften Glocken überhaupt zu Qualitätsproblemen im Produkt geführt hätten.

Die Präzision beschreibt somit die fehlerhaften Zuordnungen, die in den betrachteten Fällen in der gleichen Größenordnung liegen, was entscheidend für den Erfolg ist, da ansonsten die Akzeptanz des Systems leidet.

Fazit

Das Projekt hat somit gezeigt, dass die Inline-Prozessüberwachung des Sprays relevante Lackierfehler verlässlich detektiert, noch während das Bauteilbeschichtung. Werden diese Prozessdaten angereichert

mit den Anlagen und den Produktqualitätsdaten kann auf Basis des Random Forrest Algorithmus zusätzlich die Fehlerursache mit über 90%iger Treffsicherheit bestimmt werden.

Die Vernetzung dieser Qualitätsdaten und die sinnvolle Nutzung von KI kann so dazu beitragen, dass günstiger produziert werden kann. //

Autoren

Dr. Oliver Tiedje

Geschäftsbereichsleiter Beschichtungen und multifunktionale Materialien
Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA, Stuttgart
oliver.tiedje@ipa.fraunhofer.de
www.ipa.fraunhofer.de

Dr. Meiko Hecker

Geschäftsführer
AOM-Systems GmbH, Heppenheim
MH@AOM-Systems.com
www.aom-systems.com