

## Automatisiertes Bildverarbeitungssystem zur Kontrolle von komplex-gebogenen Oberflächen

# KI ermöglicht automatisierte Qualitätskontrolle

B. Denkena, H. Buhl, J. Geggier

**ZUSAMMENFASSUNG** Die Qualitätskontrolle geschliffener Oberflächen erfolgt bei komplexen Geometrien meist manuell, da automatisierte Systeme mit einem hohen Parametrierungsaufwand einhergehen. Dieser Beitrag stellt ein automatisiertes System zur Prüfung komplex-gebogener Aluminiumprofile vor. Zum Einsatz kommen eine robotergeführte Industriekamera für die Datenerfassung sowie Methoden der Bildverarbeitung und künstlichen Intelligenz (KI) zur Datenanalyse, die den Parametrierungsaufwand reduzieren.

### STICHWÖRTER

Künstliche Intelligenz, Bildverarbeitung, Qualitätssicherung

**AI enables automated quality control – Automated image processing system for the inspection of complex curved surfaces**

**ABSTRACT** The quality control of ground surfaces is often done manually for complex geometries, as automated systems are associated with a high parameterization effort. This article presents an automated system for inspecting complex curved aluminium profiles. A robot-guided industrial camera is used for data acquisition, as well as image processing and artificial intelligence (AI) methods for data analysis, which reduce the parameterization effort.

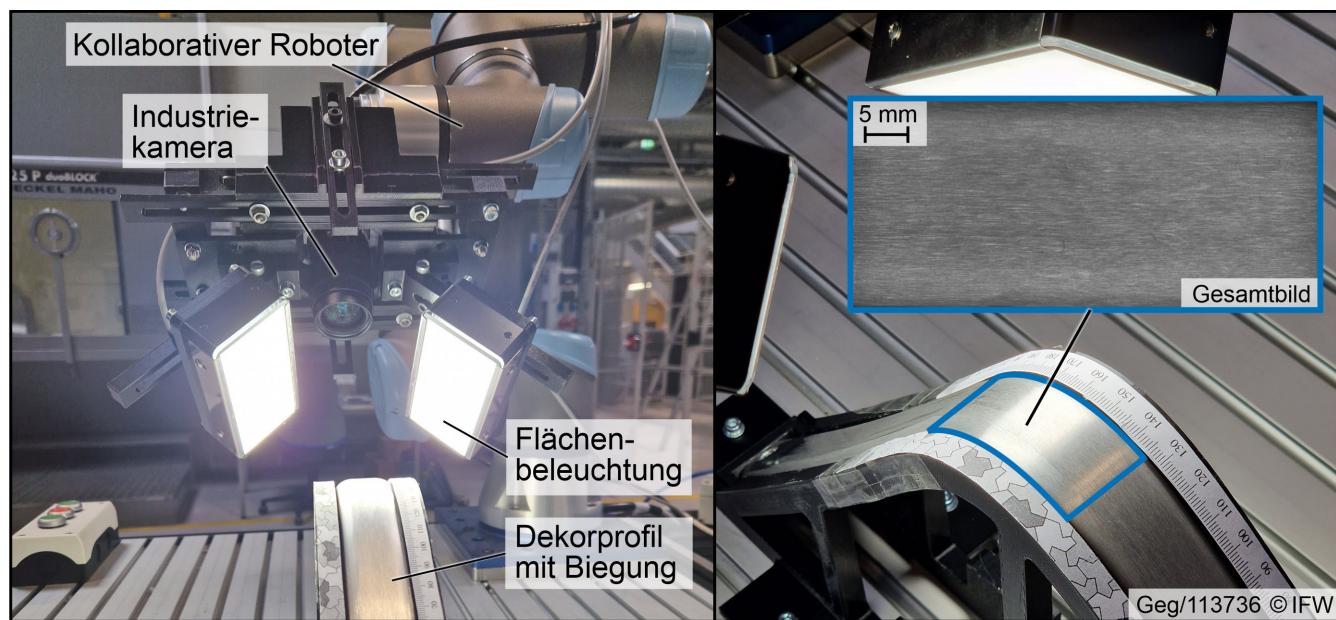


Bild 1. Robotergeführtes Bildaufnahmesystem zur automatisierten Qualitätsbewertung. Foto: IFW

### 1 Prüfung gebogener Bauteiloberflächen

In Passagierkabinen von Flugzeugen werden Aluminiumprofile als dekorative Sichtprofile verwendet. Die Dekorprofile zeichnen sich durch ein gleichmäßiges Schliffbild (Bild 1) auf einer komplex-gebogenen Oberfläche mit einer hohen Anzahl an Geometrievarianten aus.

Ein weiterer Technologietrend ist der Einsatz bioinspirierter Strukturen, die ebenfalls mit komplexen Freiformflächen einhergehen [1]. Aufgrund der komplexen Freiformflächen erfolgt die Qualitätskontrolle meist, wie auch bei dekorativen Profilen, als manuelle Sichtkontrolle. Dies führt zu einer hohen personellen Auslastung und subjektiven Ergebnissen, da die Beurteilung von der individuellen Wahrnehmung des Prüfpersonals abhängt.

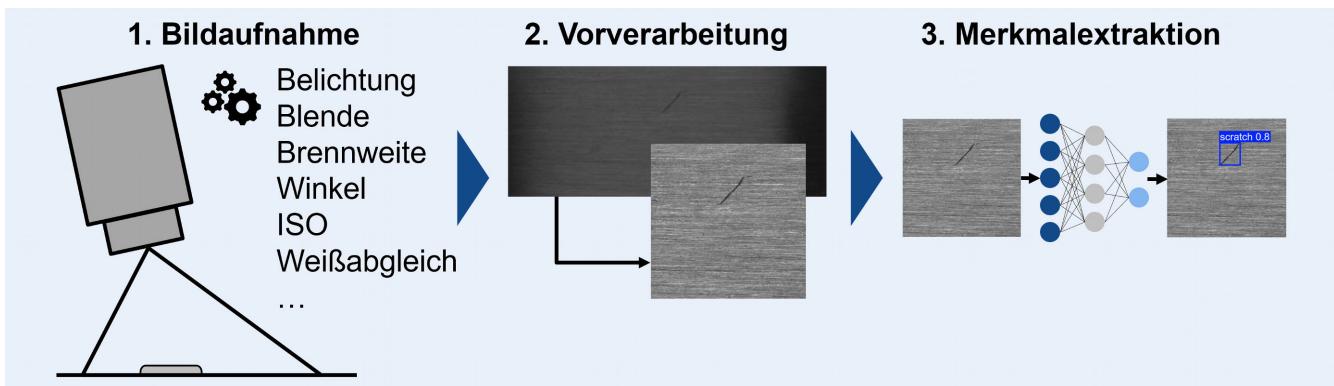


Bild 2. Industrielle Bildverarbeitung. Grafik: IFW

Im Forschungsprojekt „Automatisierung des Dekorschleifprozesses für komplexe geformte Aluminiumprofile“ (AuDeko) wurde daher von der A&T Manufacturing GmbH, der SHL AG und dem Institut für Fertigungstechnik und Werkzeugmaschinen (IFW) der Leibniz Universität Hannover neben der automatisierten Fertigung, die automatisierte Qualitätskontrolle von komplexbogigen Dekorprofilen untersucht. Der KI-gestützte Ansatz wird in diesem Beitrag vorgestellt. Die Methodik ist aber nicht nur auf Dekorprofile beschränkt, sondern lässt sich auch auf gebogene Oberflächen in anderen Anwendungsbereichen übertragen.

## 2 Klassische Bildverarbeitungsansätze: Von der Bildaufnahme bis zur Merkmalsextraktion

Prozessketten zur optischen Qualitätskontrolle bestehen in der industriellen Bildverarbeitung aus den drei Schritten Bildaufnahme, Vorverarbeitung und Merkmalsextraktion (Bild 2).

Insbesondere die Bildaufnahme von gebogenen Oberflächen ist herausfordernd, da Störeffekte im Bildbereich auftreten können, welche die Merkmalsextraktion beeinflussen. Typische Störeffekte sind Schattenwurf aufgrund der Beleuchtung sowie perspektivische Verzerrung, Unschärfe und Vignettierung durch die optische Abbildung des Objektivs [2]. Klassische Ansätze der Bildverarbeitung setzen eine statische Umgebung voraus, da ihre Robustheit im Vergleich zu KI-basierten Methoden begrenzt ist. Mit KI-basierten Ansätzen ist die Merkmalsextraktion auch mit überlagerten Störeffekten möglich. Dies erfordert jedoch einen umfangreichen Datensatz, der alle relevanten Fälle abdeckt. Eine Alternative stellt hier die Kompensation der Störeffekte dar. Zur Kompensation sind unterschiedliche Ansätze bekannt, die sowohl bei der Bilddatenaufnahme als auch in der Vorverarbeitung eingesetzt werden und in Abschnitt 2.1 vorgestellt werden [3–11].

### 2.1 Kompensation von Störeffekten bei der Bildaufnahme und Vorverarbeitung

Perspektivische Verzerrungen können unter anderem hardwareseitig, etwa durch die Verwendung von Zeilenkameras und 3D-Stereokameras, oder softwareseitig durch die Kamerakalibrierung reduziert oder vermieden werden. Bei der hardwareseitigen Kompensation mit Zeilenkameras wird schrittweise eine einzelne Pixelzeile aufgenommen. Dadurch werden rotationssymmetrische

Geometrien auf eine Ebene projiziert, was perspektivische Verzerrungen, Unschärfe und Vignettierung vermeidet [3, 4]. Nachteilig dabei ist die notwendige Synchronisation zwischen Objekt- und Aufnahmegeschwindigkeit, um Ungenauigkeiten der 2D-Projektion zu verhindern [5]. Diese Synchronisation entfällt bei der Nutzung kostengünstigerer 2D-Kameras mit Flächensensoren. Durch den größeren Bildbereich treten jedoch vor allem in den Randbereichen objektivbedingte Verzerrungen auf, die es nachträglich softwareseitig zu kompensieren gilt [6].

Alternativ werden bei Stereo-Kamerasystemen die Tiefeninformationen durch Bildaufnahme aus unterschiedlichen Perspektiven errechnet und eine 3D-Punktwolke erstellt [7, 8]. Die Punktwolke bietet eine 3D-Darstellung des Objekts, die unabhängig von der ursprünglichen Kameraperspektive ist. Durch Projektion der 3D-Darstellung in einen 2D-Bildbereich werden objektivbedingte Verzerrungen vermieden. Die Erfassung der Punktwolke bedingt jedoch bei Objektgrößen im dreistelligen Millimeterbereich einen erheblichen Rechenaufwand im Minuten- bis Stundenbereich mit High-End-Prozessoren [8]. Zudem ist häufig eine Kompensation des Messrauschens erforderlich, das bei der Erfassung von Punktwolken auftritt. Softwareseitig kann die Kompensation der perspektivischen Verzerrung ebenso während der Vorverarbeitung erfolgen. Dazu wird eine Koordinatentransformation der Pixelwerte auf Grundlage eines geometrischen Modells des zu prüfenden Objekts durchgeführt [9]. Für die Entzerrung ist allerdings eine Synchronisation zwischen Modell und Bildausschnitt nötig [10]. Darüber hinaus treten Ungenauigkeiten durch geometrische Abweichungen zwischen dem Modell und dem Objekt auf.

Analog zur perspektivischen Verzerrung können Schatten sowohl hardware- als auch softwareseitig kompensiert werden. Hardwareseitig erfolgt dies durch eine angepasste Beleuchtungsstrategie. Insbesondere bei einer hohen Variantenvielfalt der zu prüfenden Geometrie ist es jedoch nicht praktikabel alle Störeinflüsse mit der Beleuchtung zu kompensieren. Zur softwareseitigen Entfernung von Schatten bei der Vorverarbeitung der Bilddaten liegen zahlreiche Ansätze vor, die hauptsächlich auf Methoden des überwachten maschinellen Lernens basieren [11]. Zum Training der KI-Methoden werden dabei Datensätze mit schattenbehafteten und schattenfreien Bildern der gleichen Szene verwendet, um die KI-Netze auf die Schattenentfernung zu adaptieren. Der Nachteil der Methoden des maschinellen Lernens ist jedoch der hohe Aufwand zur Erzeugung des Trainingsdatensatzes.

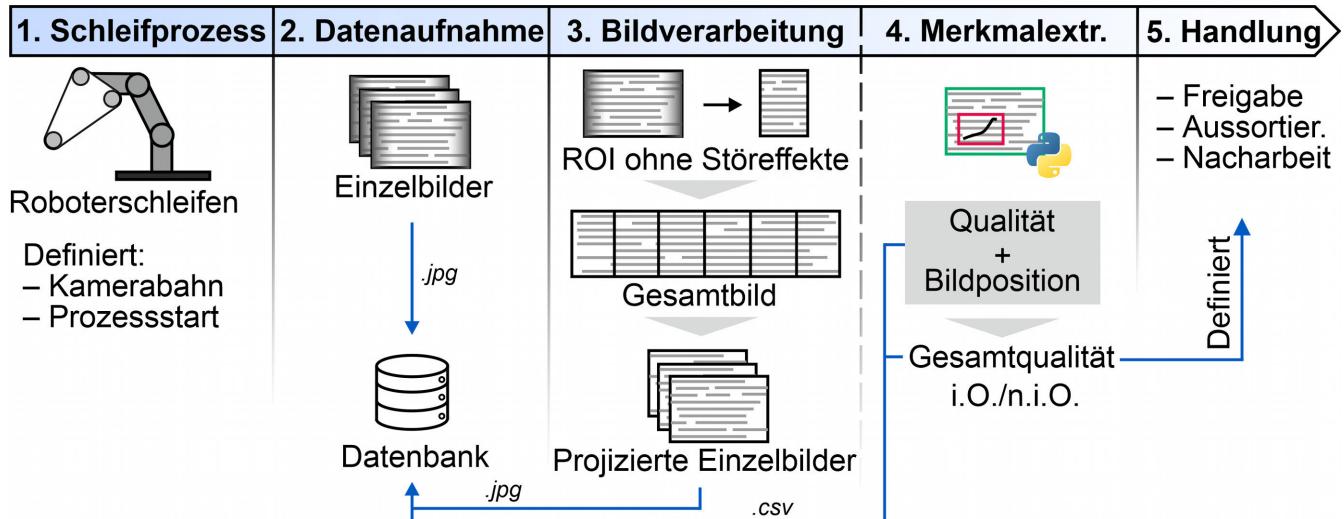


Bild 3. Prozesskette zur automatisierten Ermittlung der Oberflächenqualität komplex-gebogener Bauteile. Grafik: IFW

## 2.2 Von den Bilddaten zur Bauteilqualität mittels Merkmalsextraktion

Eine zuverlässige und präzise Datenerfassung inklusive Compensation der Störeffekte bildet die Grundlage für die Analyse der Bauteilqualität. Anhand der erfassten Daten werden mit Methoden des maschinellen Lernens Merkmale, wie die Oberflächentextur und Defekte, erfasst. Grundsätzlich wird die Extraktion von globalen und lokalen Merkmalen unterschieden. Bei dekorativen Sichtprofilen stellt die Oberflächentextur ein globales Merkmal (siehe unten Bild 6b) und die Oberflächendefekte ein lokales Merkmal (siehe unten Bild 7b) dar. Grundlegend kann die globale Textur in den Bilddaten durch die Analyse der Pixelwerte mit Operatoren erster und zweiter Ordnung beschrieben werden [12]. Operatoren erster Ordnung geben statistische Eigenschaften wie Mittelwert und Varianz der Pixelwerte wieder, während Operatoren zweiter Ordnung Beziehungen zwischen den Pixelwerten einbeziehen und somit die globale Bildtextur charakterisieren. Operatoren zweiter Ordnung werden auch bei der Lokalisierung von Defekten verwendet [13]. Im Allgemeinen erfordern klassische Bildverarbeitungsmethoden jedoch eine gezielte Wahl der Schwellwerte und Variablen und sind somit mit hohem Erfahrungswissen und Aufwand verbunden.

Für die Erkennung globaler und lokaler Merkmale haben sich Ansätze des maschinellen Lernens (ML) als effektiv erwiesen, da ein vergleichsweise geringer Parametrierungsaufwand erforderlich ist [14–16]. Als Beispiel seien hier faltende neuronale Netzwerke (englisch: Convolutional Neural Network, CNN) genannt, welche besonders leistungsfähig bei der Erkennung von Mustern in Bilddaten sind [14]. Zur Lokalisierung von Defekten werden die relevanten Bereiche im Datensatz mithilfe von Begrenzungsrahmen (englisch: Bounding Box) manuell markiert, bevor ein anschließendes Training des CNN durchgeführt wird. Hierbei findet unter anderem das YOLO-Framework Anwendung [15]. In [16] wurde beispielsweise für die Lokalisierung von Defekten auf metallischen Oberflächen mittels CNN eine Mean Average Precision (mAP) = 0,83 erreicht. Dabei ist mAP eine Metrik zur Bewertung der Vorhersage eines künstlichen neuronalen Netzwerks und nimmt Werte im Bereich 0 bis 1 an. Ein Wert von 1

gibt dabei eine ideale Übereinstimmung zwischen der Detektion durch das Netzwerk und den wahren Labeln an.

## 2.3 Transfer für die Qualitätskontrolle komplex-gebogener Oberflächen

Der Stand der Technik verdeutlicht, dass zur Automatisierung der Qualitätskontrolle sowohl eine Methode zur robusten und flexiblen Datenaufnahme ohne Störeffekte als auch eine Methode zur robusten Merkmalsextraktion benötigt werden. Stationäre Zeilenkameras eignen sich zur Kompensation von Störeffekten, erfordern jedoch eine Synchronisierung und sind auf geometrisch einfache Oberflächen beschränkt.

Um die flexible Qualitätskontrolle komplex-gebogener Dekorprofile zu realisieren, wird daher eine Kamera von einem Roboter orthogonal zur Bauteilloberfläche geführt. Um Ungenauigkeiten der Roboterbahn und schwankende Bahngeschwindigkeiten auszugleichen, wird eine Kamera mit Flächensor eingesetzt, die zur Kompensation der Störeinflüsse Informationen benachbarter Pixelzeilen berücksichtigt. Sowohl für die Klassifikation der Textur als auch die Lokalisierung von Oberflächendefekten werden für den vorliegenden Anwendungsfall CNN genutzt. Diese zeichnen sich aus durch die Fähigkeit zur Generalisierung durch einen umfangreichen, gelabelten Datensatz bei geringem Auslegungs- und Parametrierungsaufwand. Ein weiterer Grund ist die hohe Robustheit gegenüber wechselnden Umgebungsbedingungen.

## 3 Bildverarbeitung zur Qualitätskontrolle komplex-gebogener Oberflächen

Das in diesem Beitrag vorgestellte Automationssystem zur Qualitätskontrolle komplex-gebogener Dekorprofile baut auf den Ergebnissen von Denkena *et al.* zur Qualitätskontrolle ebener Oberflächen auf [17, 18]. Dort wurde gezeigt, dass Oberflächendefekte und -texturen mittels CNN auf dekorativen Bauteilen erfolgreich detektiert werden [17, 18]. Die vorgestellte Methode basiert auf der Pearson-Korrelation, um Einzelbilder gerader Oberflächen zusammenzufügen [18, 19]. Der vorliegende Beitrag erweitert das System um die Bildaufnahme und -vorverarbeitung von ebenen Oberflächen auf gebogene Oberflächen und passt die

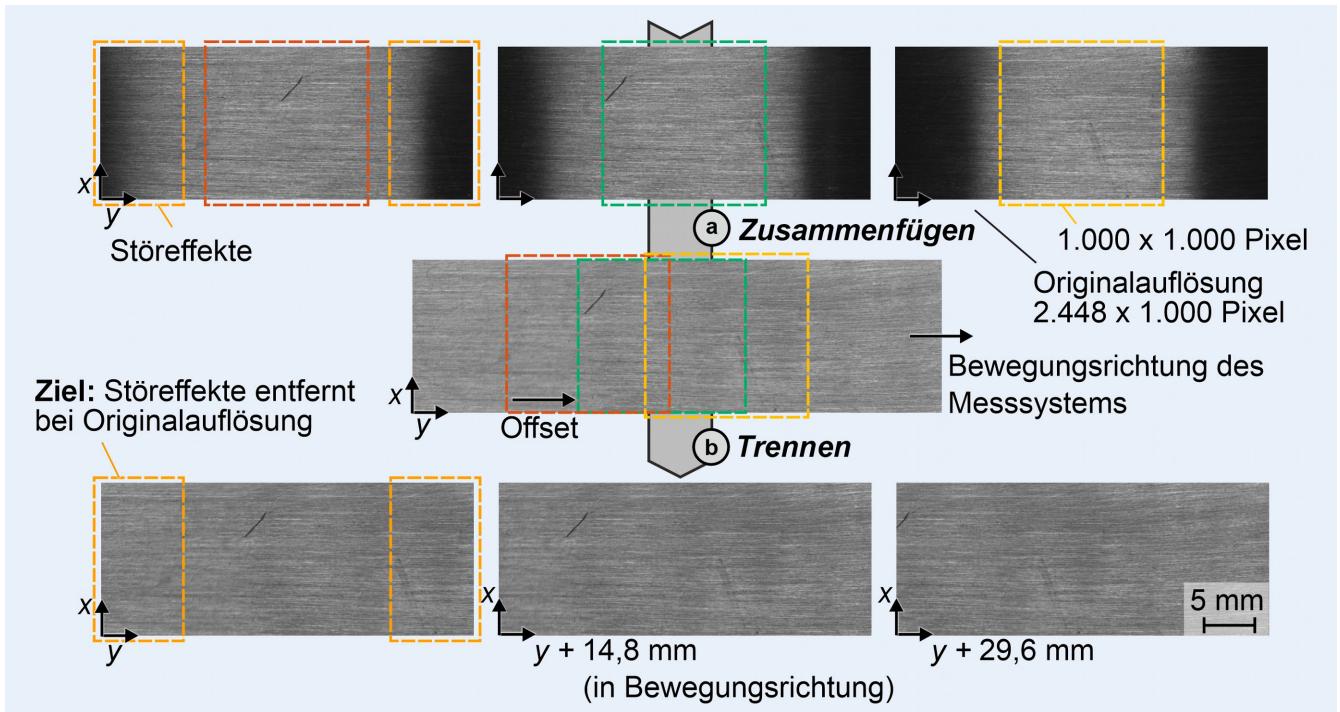


Bild 4. Funktionsprinzip der Bildprojektion zur geometrieunabhängigen Qualitätskontrolle. Grafik: IFW

CNN für diesen Anwendungsfall an. Zur Realisierung des Automationssystems enthält die Prozesskette die Schritte Bildaufnahme, Vorverarbeitung und Merkmalsextraktion (**Bild 3**).

Der Schleifprozess (1) definiert zunächst die zu prüfende Bauteilgeometrie. Mit den Geometrieeinformationen des Bauteils wird die Kamerabahn berechnet. Dabei bleiben Arbeitsabstand und Aufnahmewinkel der Kamera für ein reproduzierbares und homogenes Bild konstant. Im Anschluss erfolgt die Bildaufnahme und -speicherung (2) in einer Datenbank. Da die Bilddaten Störeffekte enthalten, werden diese mit Projektionsalgorithmen (3) entfernt. Die bereinigten Bilddaten werden positionsabhängig in der Datenbank gespeichert und Qualitätsmerkmale (4) von jedem Bild extrahiert. Die Qualitätsmerkmale definieren im Zusammenhang mit der Position die Gesamtqualität des Bauteils. Mit einer Handlungslogik (5) wird schließlich ein Handlungsschritt (Freigabe, Aussortierung, Nacharbeit) in Abhängigkeit von Qualitätsgrenzen ermittelt. Die so definierte Prozesskette bietet den Vorteil, dass die Bauteilqualität geometrieunabhängig und ganzheitlich ermittelt wird. Die Schritte der Bewertung und Handlungsempfehlung werden nachfolgend erläutert.

### 3.1 Datenaufnahme: Robotergeführte Industriekamera sorgt für Flexibilität

Für die Bildaufnahme wurde eine Monochromkamera des Typs „DMK 33GX264“ der Imaging Source GmbH mit einer Auflösung von 5 Megapixel und einer maximalen Aufnahmefrequenz von 24 Bildern pro Sekunde ausgewählt (siehe Bild 1). Diese ist mit einem entozentrischen Objektiv mit einem Arbeitsabstand von 100 mm und einer Blende von F16 ausgestattet. Zur beidseitigen Beleuchtung der Dekorprofile fanden zwei Weißlichtleuchten Anwendung. Auf eine Umhausung zum Schutz vor Fremdlicht konnte verzichtet werden, da Bilddaten unter kontrollierten Lichtbedingungen mit einer kurzen Belichtungszeit

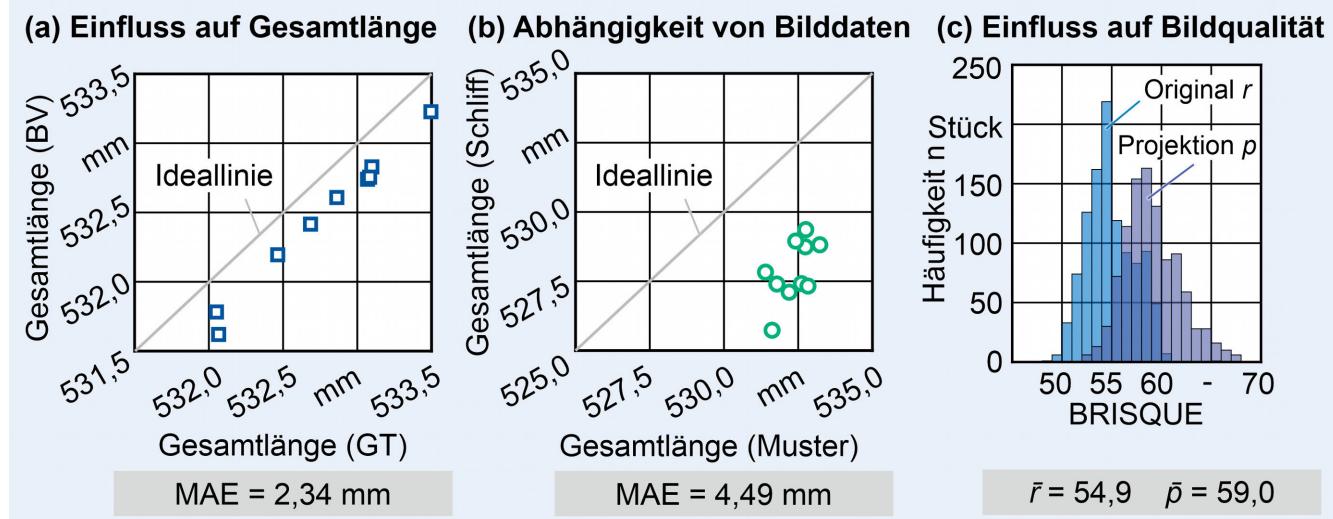
(1/750 Sekunden) bei heller Beleuchtung (circa 49 kLux) aufgenommen wurden.

Das Kamerasystem wurde von einem Roboter Typ „UR5e“ mit einer Reichweite von 850 mm geführt, um die Bilddatenaufnahme von komplex-gebogenen Oberflächen zu ermöglichen. Mit dem Aufbau wird eine Aufnahmefläche von ungefähr 534 mm<sup>2</sup> für jede Einzelaufnahme abgedeckt. Zur Vorverarbeitung der Bilddaten werden diese dann in einer Datenbank im JPEG-Format gespeichert.

### 3.2 Bildverarbeitung: Projektion der Bilddaten auf eine Ebene

Die aufgenommenen Bilddaten weisen Störeffekte auf, die durch geeignete Vorverarbeitungsschritte kompensiert werden. Um durch die Bildprojektion Störeffekte zu entfernen, erfolgt im ersten Schritt das Zusammenfügen der Bilddaten (**Bild 4a**).

Die Rohbilder (2448 x 1000 Pixel) von der Oberfläche werden zunächst auf einen Bereich (1000 x 1000 Pixel), der keine Störeffekte enthält, zugeschnitten. Je nach Anwendung und Breite der Störeffekte im Randbereich kann der Zuschnitt größer oder kleiner erfolgen. Die Verarbeitungszeit erhöht sich allerdings mit zunehmender Anzahl an Zuschnitten. Nach dem Zuschnitt erfolgt die Schätzung eines Offsets zwischen den Einzelbildern, um den Suchbereich definiert wird. Innerhalb des Suchbereichs werden die Einzelbilder zueinander verschoben und die Verschiebung mit der höchsten Korrelation wird als tatsächliche Bildverschiebung für das Zusammenfügen zu einem Gesamtbild angewendet. Als Grundlage dient hierbei die Pearson-Korrelation [17, 18]. Abschließend liegt ein zusammengefügtes Gesamtbild für das gesamte Bauteil vor. Im zweiten Schritt wird das Gesamtbild aufgetrennt, um unabhängig von der Bauteillänge konsistente Bildauflösungen (2448 x 1000 Pixel) für die Merkmalsextraktion auf den Einzelbildern sicherzustellen (**Bild 4b**). Durch den



**Bild 5.** Einfluss der Bildprojektion auf die berechnete Gesamtlänge (a) sowie Abhängigkeit der Bildprojektion von Bilddaten (b) und Einfluss der Projektion auf die Bildqualität (c). *Grafik: IFW*

Projektionsprozess ist die globale Zuordnung der Einzelbilder auf das Bauteilkordinatensystem möglich und die projizierte Gesamtlänge des Bauteils kann ermittelt werden.

Wesentliche Voraussetzung für die zuverlässige Lokalisierung der Qualitätsmerkmale im Bauteilkordinatensystem ist eine hohe Übereinstimmung zwischen berechneter und tatsächlicher Gesamtlänge des Bauteils. **Bild 5a** zeigt die ermittelte Gesamtlänge durch den Bildverarbeitungsprozess (BV) gegenüber den wahren Werten (englisch: Ground Truth, GT) und gibt somit Aufschluss über die Genauigkeit der Bildprojektion.

Damit die Ergebnisse nicht durch die Grauwertverteilung der Bilddaten negativ beeinflusst werden, wurden geometrische Muster auf den gebogenen Bauteilen zur eindeutigen Korrelationsberechnung genutzt. Es zeigte sich auf einem Datensatz mit zehn gebogenen Bauteilen ein durchschnittlicher Fehler von 2,34 mm beziehungsweise 0,44 % bezogen auf die Gesamtlänge. Gründe für die Abweichung sind, dass sich durch Bildpixel nur diskrete Werte ergeben können und Ungenauigkeiten bei der Korrelationsberechnung zur ungenauen Berechnung der Gesamtlänge führen. Durch einen Offset konnte die Abweichung in der Längenberechnung behoben werden. Die Berechnung der Gesamtlänge wies für ein einzelnes Bauteil mit zehn Wiederholmessungen eine Wiederholgenauigkeit von 0,16 % auf. Die maximale Abweichung betrug dabei 0,27 %. Folglich ist festzuhalten, dass ein zuverlässiger und reproduzierbarer Prozess der Bildzusammenfügung vorliegt.

Eine weitere Grundlage für den zuverlässigen Einsatz der Projektionsmethode ist die Robustheit gegenüber der Grauwertverteilung in den Einzelbildern, die abhängig vom Schliffbild ist. Im nächsten Schritt wurde daher untersucht, inwieweit die Berechnung der Gesamtlänge von der Grauwertverteilung abhängt. Dazu erfolgte der Vergleich der berechneten Gesamtlänge mittels Bildverarbeitung von Dekoroberflächen gegenüber eindeutigen geometrischen Mustern. In Bild 5b wird die berechnete Gesamtlänge zusammengefügter Bilder mit Schliffoberfläche und mit geometrischen Mustern vergleichend dargestellt. Grundlage war ein Datensatz aus zehn gebogenen Bauteilen. Bei gleicher Bauteillänge wurde mit den Einzelbildern mit geometrischem Mustern eine um 4,49 mm längere Gesamtlänge als bei den Einzelbildern mit Dekorschliffen berechnet. Der Grund ist, dass die wiederho-

lenden geometrischen Muster eine präzisere Korrelationsberechnung ermöglichen und sich somit genauere Verschiebungswerte für das Zusammenfügen ergeben. Der Einfluss der Grauwertverteilung lässt sich als nicht signifikant einordnen, da prozentual eine Ungenauigkeit von 0,85 % vorliegt.

Zur Bewertung des Einflusses der Bildprojektion auf die Bildqualität fand der Brisque-Wert (Blind/Referenceless Image Spatial Quality Evaluator) Berücksichtigung. Der Brisque-Wert bewertet Bildrauschen, Unschärfe und Kompressionsartefakte auf den Bilddaten [17]. Die Bildqualität geschliffener Bauteiloberflächen wurde durchschnittlich um 7,5 % verschlechtert (Bild 5c), was auf Unschärfe in den Bildern aufgrund unpassender Zuordnungen der Grauwerte während der Bildprojektion zurückzuführen ist. Durch die iterative Anpassung der Parameter des Projektionsalgorithmus konnte keine höhere Bildqualität erzielt werden. Um den Einfluss der Bildqualität auf die Merkmalsextraktion zu mindern, wurden in den Grunddatensatz für das Training der Merkmalsextraktion ebenso projizierte Einzelbilder aufgenommen.

### 3.3 Merkmalsextraktion: CNN-basierte Ermittlung der Bauteilqualität

Nach der Projektion der Einzelbilder zur Kompensation von Störeffekten erfolgt die Extraktion der Qualitätsmerkmale. Die Oberflächenqualität wird durch die Merkmale Texturqualität und Oberflächendefekte charakterisiert. Für beide Merkmale wird ein überwachter Lernansatz verwendet. Dazu wurde mit einer Datengrundlage von 976 Einzelbildern ein CNN für die drei Klassen in Ordnung (i.O.), nicht in Ordnung (n.i.O.) und Rohteil (Roh) trainiert. Als CNN-Architektur wurde „YOLOv8“ der Ultralytics Inc. verwendet, da dieses auf Normdatensätzen sehr hohe Genauigkeiten erreicht [15]. Für das Training von Klassifizierungsmodellen wurden auf dem ImageNet-Datensatz [18] vortrainierte Netze in unterschiedlicher Größe von der Ultralytics Inc. bereitgestellt. Diese reduzieren die Trainingszeit wesentlich und weisen in der Regel nach abgeschlossenem Training eine höhere Erkennungsgüte auf den eigenen Daten auf [19]. In Abhängigkeit der Modellgröße wurden Genauigkeiten zwischen  $A_s = 0,90$  beim

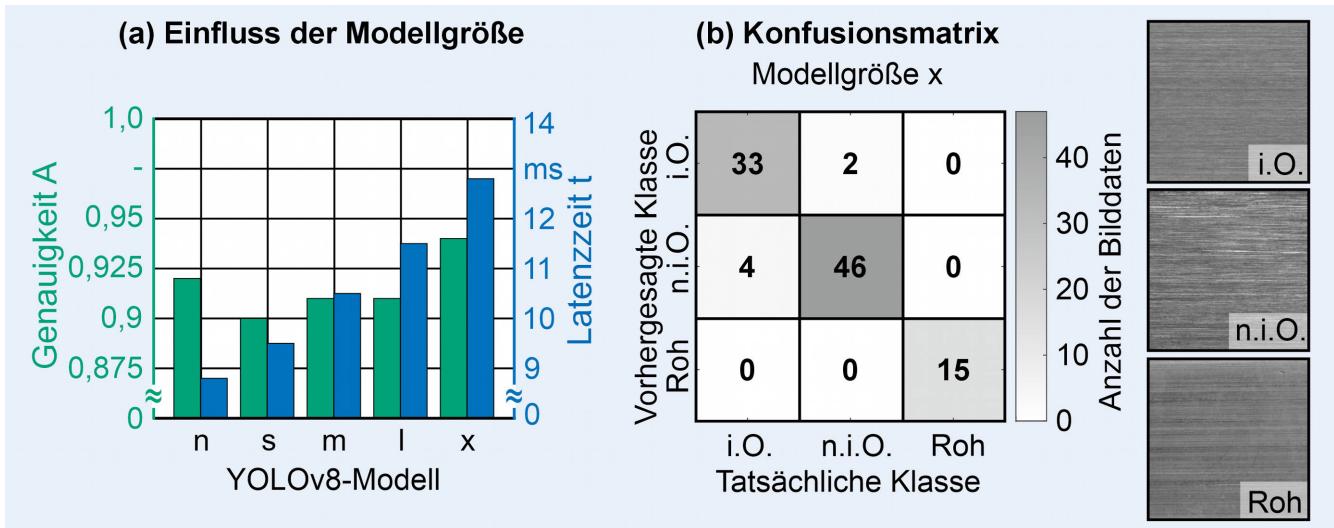


Bild 6. Klassifikation der Texturqualität in i.O., n.i.O. und Rohteil mittels CNN. Grafik: IFW

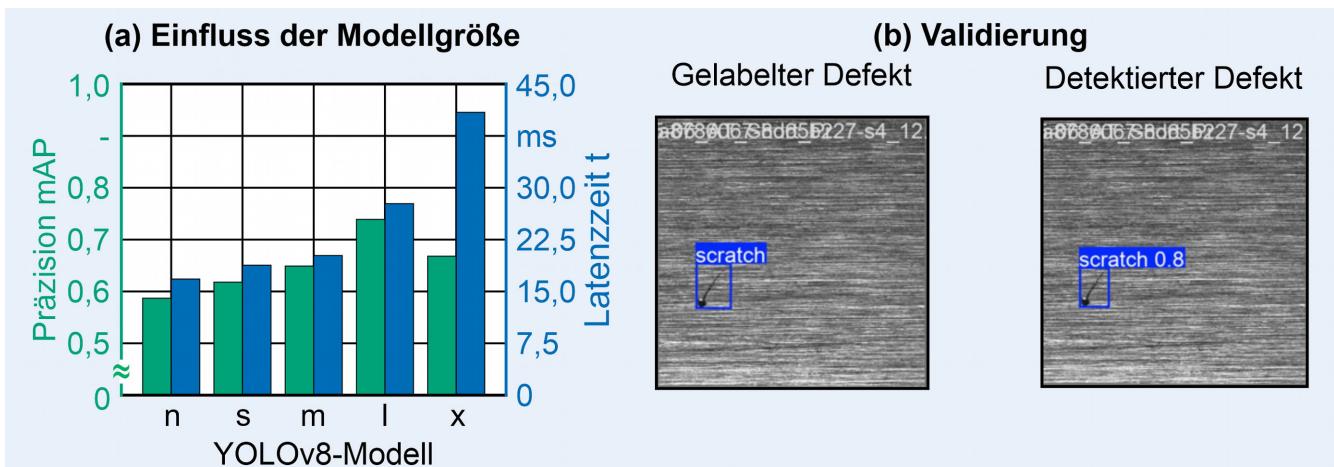


Bild 7. Lokalisierung von Defekten auf dekorativen Oberflächen mittels CNN. Grafik: IFW

s-Modell bis zu  $A_x = 0,94$  beim x-Modell auf einem zuvor unbekannten Testdatensatz erreicht (Bild 6a).

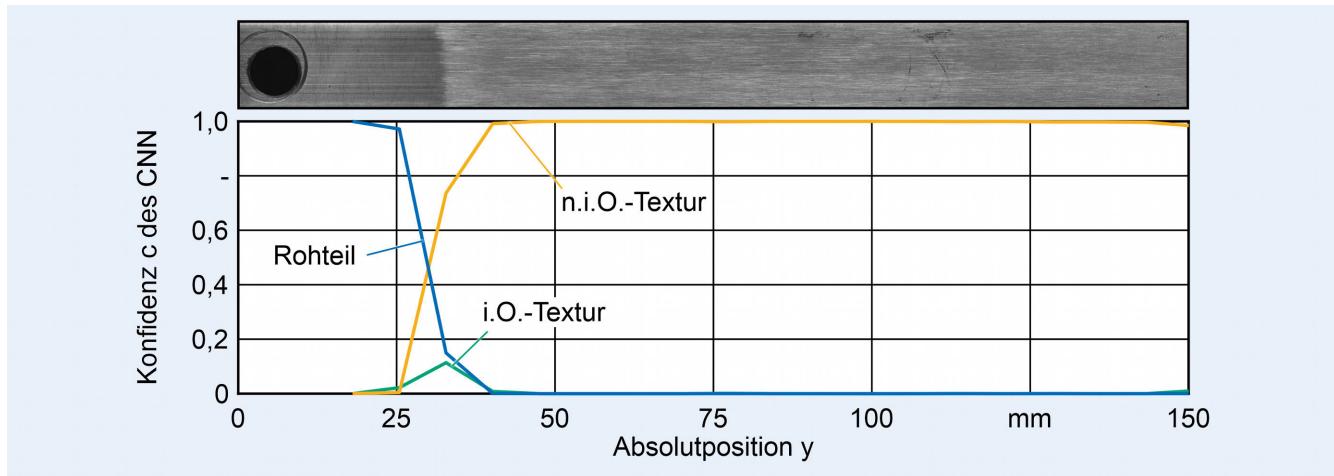
Die Latenzzeit für die Klassifikation auf einer GPU des Typs „Nvidia RTX A4000“ steigt dabei abhängig von der Modellgröße schrittweise von  $t_n = 8,8$  ms bis  $t_x = 12,8$  ms an. Da die Bildaufnahme in der vorliegenden Anwendung langsamer als die maximale Latenzzeit war, wurde die Modellgröße x als CNN mit der höchsten Genauigkeit gewählt. Das n-Modell erreicht trotz der kleinsten Modellgröße die zweithöchste Klassifikationsgenauigkeit. Grund hierfür ist, dass für die Erkennung von geometrischen Texturen, die größtenteils aus Kanten bestehen, nicht zwingend komplexe neuronale Netzwerke benötigt werden. Die Konfusionsmatrix für die Modellgröße x veranschaulicht, dass das CNN für die Ermittlung der Texturqualität auf unbekannten Bilddaten ein F-Maß (Makro) von  $F_1 = 0,95$  erreicht (Bild 6b). Dies ist als hoch einzutragen und somit für die Qualitätskontrolle geeignet.

Neben der Texturqualität wird die Oberflächenqualität von lokalen Defekten beeinflusst (Bild 7b). Der Wert neben der erkannten Defektklasse „scratch“, englisch für Kratzer, gibt die Konfidenz des Models an.

Im gezeigten Beispiel gibt das Modell somit aus, dass es sich mit einer Konfidenz von 0,8 um einen Kratzer handelt. Defekte

entstehen durch Beschädigungen des Schleifbands, Ablagerungen auf der Werkstückoberfläche oder fehlerhafte Handhabung. Die lokalen Defekte lassen sich ebenfalls mithilfe eines CNN auf Basis der YOLO-Architektur ermitteln. Das Training des Modells erfolgte auf einem Bilddatensatz von 297 Bildern.

Für die Objekterkennung werden von der Ultralytics Inc. ebenfalls vortrainierte Modelle bereitgestellt, die auf dem COCO-Datensatz basieren [20]. Für die Bewertung der Detektionsgenauigkeit wird die mAP für eine Intersection over Union (IoU) von 0,5 genutzt. Das heißt, wenn zwischen dem Label und der Vorhersage des Modells eine  $\text{IoU} \geq 0,5$  erreicht wird, gilt die Vorhersage als wahr, ein kleinerer gilt als falsch. Die mAP berechnet sich im Anschluss aus der Anzahl an richtigen und falschen Vorhersagen für unterschiedliche Schwellenwerte der Konfidenz. Eine mAP von 1 entspricht dem bestmöglichen Ergebnis. Eine Übersicht zu erreichten mAPs in Abhängigkeit der Modellgröße ist in Bild 7a dargestellt. Die Modelle erreichen eine mAP zwischen  $mAP_n = 0,59$  bis  $mAP_l = 0,74$  auf dem zuvor unbekannten Testdatensatz. Die höchste  $mAP_l$  wird dabei nach 252 Trainingsepochen mit dem l-Modell erzielt. Bei der Defektlokalisierung liegt die Latenzzeit zwischen  $t_n = 16,8$  ms bis  $t_x = 40,9$  ms.



**Bild 8.** Positionsauflöste Texturklasse im Übergangsbereich zwischen Rohteil und n.i.O.-Textur. *Grafik: IFW*

Die Genauigkeit der Kratzerdetektion ist geringer als die Genauigkeit der Texturklassifikation. Dies ist mit der Komplexität der Aufgabe zu begründen. Aufgrund der Komplexität und damit der Netzarchitektur ist die Latenzzeit bei der Defektlokalisierung länger als bei der Texturklassifikation, jedoch weiterhin kürzer als die Bildaufnahmzeit mit einem Bild pro Sekunde. Zum Nachweis der Funktionsfähigkeit des gewählten Ansatzes ist das CNN geeignet. Zukünftig kann die Genauigkeit der Detektion durch einen umfangreichen Datensatz, der parallel zur Produktion aufgenommen wird, erhöht werden.

### 3.4 Handlung: Identifikation von Nacharbeitsbereichen

Die berechneten Qualitätsmerkmale werden nach jeder Qualitätskontrolle positionsauflöst gespeichert, um eine Bewertung der gesamten Bauteilqualität vorzunehmen. Damit ist es möglich, die Bilddaten auf das Bauteilkoordinatensystem zu beziehen und die Stellen der Nacharbeit zu identifizieren. Die Position wird auf Grundlage der Bildprojektion berechnet. Dazu wird die Position der Bildmitte als Absolutposition für jedes Bild ermittelt. Die projizierten Einzelbilder werden mit einem Abstand von 7,4 mm in y-Richtung aus dem Gesamtbild erzeugt. **Bild 8** zeigt beispielhaft einen vom Automationssystem ermittelten Plot der positionsauflösten Texturklasse für ein gebogenes Dekorprofil.

Im Ausschnitt des projizierten Bildes ist zu erkennen, dass ein Übergangsbereich zwischen Rohteil-Textur und n.i.O.-Textur vorliegt. Die Konfidenz  $c$  des CNN zur Klassifikation der Rohteil-Textur liegt bei einer Absolutposition  $0 \leq y \leq 25$  mm entsprechend bei  $c > 0,95$ . Bei Positionen  $y > 40$  mm wird die Texturklasse n.i.O. mit  $c > 0,95$  korrekt zugewiesen. Im Übergangsbereich liegt keine eindeutige Textur vor, weshalb für alle Klassen  $c < 0,95$  ermittelt wird. Bei unsicheren Vorhersagen ( $c < 0,95$ ) für alle Klassen ist die manuelle Kontrolle des Bauteilbereichs notwendig. Die manuell identifizierten Bereiche werden im nächsten Schritt für ein erneutes Training genutzt, um die Vorhersagegenauigkeit des Automationssystems fortlaufend zu erhöhen.

## 4 Zusammenfassung

In diesem Beitrag wurde ein neuartiger Ansatz vorgestellt, der die Qualitätskontrolle geschliffener Dekorprofile auf komplexbogigen Oberflächen bildbasiert ermöglicht. Dabei werden mit

einer robotergeführten Industriekamera mit Flächensor sensor Bilddaten der Schliffoberfläche aufgenommen, die anschließend mithilfe eines auf der Pearson-Korrelation basierenden Algorithmus auf eine Ebene projiziert werden. Die Vorteile des Vorgehens sind die Kompensation von Störeffekten im Bildbereich und die Transformation der Bilddaten in das Bauteilkoordinatensystem mit einem kostengünstigen 2D-Kamerasystem. Zudem werden bei diesem Vorgehen störfreie und einheitliche Bilddaten erzeugt und somit eine Generalisierung des Modells auch bei kleiner Datengrundlage ermöglicht.

Die Schliffoberflächen wurden mit dem Automationssystem hinsichtlich Texturqualität und lokaler Defekte bewertet. Für die Texturklassifikation konnte mit einem trainierten CNN ein F-Maß  $F_1 = 0,95$  und für die Lokalisierung der Kratzer eine mAP = 0,74 erreicht werden. Die Genauigkeiten und Robustheit beider CNN, vor allem für die Lokalisierung von Kratzern, kann durch eine variationsreiche Erweiterung des Datensatzes weiter gesteigert werden. Die Ergebnisse zeigen, dass sich die Methodik eignet, um eine automatisierte Qualitätskontrolle umzusetzen.

## FÖRDERHINWEIS UND DANKSAGUNG

Das Forschungsprojekt „Adaptive Roboterschleifzelle zur Herstellung von Dekorschiffen auf komplex geformten Aluminiumprofilen“ (Förder-Kennzeichen: KK5032703PK0) wurde durch das Bundesministerium für Wirtschaft und Klimaschutz (BMWK) aufgrund eines Beschlusses des Deutschen Bundestages im Rahmen des Zentralen Innovationsprogramms Mittelstand (ZIM) gefördert und wurde von der Arbeitsgemeinschaft industrieller Forschungsvereinigungen „Otto von Guericke“ (AiF) betreut. Die A&T Manufacturing GmbH, die SHL AG und das IFW Hannover bedanken sich für die finanzielle Unterstützung in diesem Projekt.

## L iteratur

- [1] Orson, B.: Sustainable Cabin Design. New Approaches in Sustainable Aircraft Interior Design. Aerospace Technology Institute – FlyZero. Stand: 2022. Internet: [www.ati.org.uk/wp-content/uploads/](http://www.ati.org.uk/wp-content/uploads/)

- 2022/03/FZO-AIR-POS-0039-Sustainable-Cabin-Design.pdf.  
Zugriff am 04.02.2025
- [2] Beyerer, J.; Puente León, F.; Frese, C. et al. (Hrsg.): Automatische Sichtprüfung. Heidelberg: Springer-Verlag 2024
- [3] Halbach, G.; Oechsner, U.: Smart Line Scan Measurement Systems. PhotonicsViews 17 (2020) 6, pp. 50–53
- [4] Beyerer, J.; Puente León, F.; Frese, C. et al.: Sensoren zur Bildgewinnung. In: Beyerer, J.; Puente León, F.; Frese, C. et al. (Hrsg.): Automatische Sichtprüfung. Heidelberg: Springer-Verlag 2024, S. 255–284
- [5] Forgács, Z.; Trohák, A.: The determination of the line of interest in a line scan camera-based measurement system. Pollack Periodica (2024), doi.org/10.1556/606.2024.01187
- [6] Zhang, Z.: A flexible new technique for camera calibration. IEEE Transactions on Pattern Analysis and Machine Intelligence 22 (2000) 11, pp. 1330–1334
- [7] Shang, H.; Liu, C.; Wang, R.: Measurement methods of 3D shape of large-scale complex surfaces based on computer vision: A review. Measurement 197 (2022), #111302, doi.org/10.1016/j.measure.2022.111302
- [8] Ramm, R.; Heinze, M.; Kühmstedt, P. et al.: Portable solution for high-resolution 3D and color texture on-site digitization of cultural heritage objects. Journal of Cultural Heritage 53 (2022), pp. 165–175
- [9] Beyerer, J.; Puente León, F.; Frese, C. et al.: Vorverarbeitung und Bildverbesserung. In: Beyerer, J.; Puente León, F.; Frese, C. et al. (Hrsg.): Automatische Sichtprüfung. Heidelberg: Springer-Verlag 2024, S. 639–708
- [10] Valente, J.; Soatto, S.: Perspective distortion modeling, learning and compensation. 2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Boston, MA, USA, 2015, pp. 9–16
- [11] Vasluiianu, F.-A.; Seizinger, T.; Zhou, Z. et al.: NTIRE 2024 Image Shadow Removal Challenge Report. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), Seattle, WA, USA, 2024, pp. 6547–6570
- [12] Ramola, A.; Shakya, A. K.; van Pham, D.: Study of statistical methods for texture analysis and their modern evolutions. Engineering Reports 2 (2020) 4, doi.org/10.1002/eng2.12149
- [13] Hoseini, E.; Farhadi, F.; Tajeripour, F.: Fabric Defect Detection Using Auto-Correlation Function. International Journal of Computer Theory and Engineering (2013), pp. 114–117
- [14] Luo, Q.; Fang, X.; Su, J. et al.: Automated Visual Defect Classification for Flat Steel Surface: A Survey. IEEE Transactions on Instrumentation and Measurement 69 (2020) 12, pp. 9329–9349
- [15] Jocher, G.; Jing, Q.; Chaurasia, A.: Ultralytics YOLO (Version 8.0.0). Internet: <https://github.com/ultralytics/ultralytics>. Zugriff am 04.02.2025
- [16] Selamet, F.; Cakar, S.; Kotan, M.: Automatic Detection and Classification of Defective Areas on Metal Parts by Using Adaptive Fusion of Faster R-CNN and Shape From Shading. IEEE Access 10 (2022), pp. 126030–126038, doi.org/10.1109/ACCESS.2022.3224037
- [17] Mittal, A.; Moorthy, A. K.; Bovik, A. C.: No-reference image quality assessment in the spatial domain. IEEE transactions on image processing 21 (2012) 12, pp. 4695–4708, doi.org/10.1109/TIP.2012.2214050
- [18] Deng, J.; Dong, W.; Socher, R. et al.: ImageNet: A large-scale hierarchical image database. 2009 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPR Workshops), Miami, FL, 2009, pp. 248–255
- [19] Ultralytics Inc.: Modelltraining mit Ultralytics YOLO. Stand: 2024. Internet: [docs.ultralytics.com/de/modes/train/](https://docs.ultralytics.com/de/modes/train/). Zugriff am 04.02.2025
- [20] Lin, T.-Y.; Maire, M.; Belongie, S. et al.: Microsoft COCO: Common Objects in Context. In: Fleet, D.; Pajdla, T.; Schiele, B. et al. (Hrsg.): Computer Vision – ECCV 2014. Cham: Springer International Publishing 2014, pp. 740–755, doi.org/10.1007/978-3-319-10602-1\_48

Prof. Dr.-Ing. Berend Denkena



Henning Buhl, M.Sc.

buhl@ifw.uni-hannover.de

Tel. +49 511 / 762-2390



Jan Geggier, M.Sc.

Foto: IFW

Leibniz Universität Hannover

Institut für Fertigungstechnik und Werkzeugmaschinen

An der Universität 2, 30823 Garbsen

[www.ifw.uni-hannover.de](http://www.ifw.uni-hannover.de)

## LIZENZ



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