

# Innovative Qualitätssicherung mittels optimierter Bildverarbeitungsketten auf Basis von Deep Learning

## Innovative quality assurance using optimized image processing chain based on deep learning

Katharina Anding<sup>1</sup>, Galina Polte<sup>1</sup>, Lilli Steinert<sup>1</sup>, Daniel Garten<sup>2</sup>,  
Marco Kraft<sup>3</sup>, Martin Welzenbach<sup>4</sup> und Claudia Gärtner<sup>3</sup>

<sup>1</sup> Technische Universität Ilmenau, Fakultät für Maschinenbau,  
Fachgebiet Qualitätssicherung und Industrielle Bildverarbeitung,  
Gustav-Kirchhoff-Platz 2, 98693 Ilmenau

<sup>2</sup> GFE Schmalkalden e.V., Näherstiller Straße 10, 98574 Schmalkalden

<sup>3</sup> microfluidic ChipShop GmbH, Stockholmer Str. 20, 07747 Jena

<sup>4</sup> Ziemann & Urban GmbH, Prüf- u. Automatisierungstechnik,  
Am Bleichbach 28, 85452 Moosinning

**Zusammenfassung** In diesem Beitrag werden intelligente Qualitätssicherungslösungen für die automatische Erkennung verschiedener Fehlerklassen im industriellen Fertigungsprozess unter Optimierung der Bildverarbeitungs- und Mustererkennungskette auf Basis von Deep Learning diskutiert. Exemplarisch werden intelligente Qualitätssicherungslösungen für die industriellen Fertigungsprozesse Kunststoffspritzguss von mikrofluidischen Bauteilen in der Medizintechnik sowie von Makrobauteilen im Automobilbau aufgezeigt. Die Anwendung leistungsfähiger Deep-Learning-Algorithmen mit ihrem Prinzipbedingt gegebenen höheren Generalisierungs- und Abstraktionsvermögen ermöglicht smarte intelligente In-Prozess-Lösungen zur Evaluierung der Fertigungsqualität und ermöglicht auch Rückschlüsse zum Fertigungsprozess selbst. In diesem Beitrag werden die relevanten Aspekte zur Lösung verschiedener industrieller Qualitätssicherungsaufgaben mittels tiefer neuronaler Netze näher beleuchtet.

**Schlüsselwörter** Deep Learning, Convolutional Neural Network (CNN), Künstliche Intelligenz

**Abstract** This paper discusses intelligent quality assurance solutions for the automatic detection of different defect classes in industrial manufacturing processes by optimizing the image processing and pattern recognition chain based on Deep Learning. Exemplary intelligent quality assurance solutions for the industrial manufacturing processes plastic injection molding of microfluidic components in medical technology as well as macro components in automotive manufacturing are shown. The application of powerful deep learning algorithms with their principle-based higher generalization and abstraction capability enables smart intelligent in-process solutions for the evaluation of manufacturing quality and also allows conclusions to be drawn about the manufacturing process itself. In this paper, the relevant aspects for solving various industrial quality assurance tasks using deep neural networks are examined in more detail.


**Keywords** Deep learning, convolutional neural network (CNN), artificial intelligence

## 1 Motivation und Ziele der vorgestellten Forschung

Qualitätssicherungsaufgaben im heutigen Produktionsumfeld haben in aller Regel, völlig unabhängig vom Produktionsprozess selbst, die Gemeinsamkeit, dass die automatisierte Qualitätsevaluierung in Form der Produktanalyse nur durch eine Übertragung des Experten-Apriori-Wissens auf ein maschinelles System umgesetzt werden kann. Hierfür werden neben einem Problem-angepassten Bildverarbeitungssystem im Falle der optischen Signalerfassung und -verarbeitung auch eine intelligente algorithmische Umsetzung der Bildverarbeitungs- und Mustererkennungskette notwendig sowie die Zusammenstellung des Experten-Apriori-Wissens in Form von manuell klassifizierten Datensätzen für ein anschließendes Klassifikatortraining. Damit wird deutlich, dass Methoden der Künstlichen Intelligenz (KI) zur Lösung heutiger Qualitätssicherungsaufgaben in der intelligenten, ressourcenschonenden industriellen Produktion unerlässlich sind. Da im Produktionsprozess in aller Regel die existierenden Fehlerklassen

bereits im Vorfeld bekannt sind und die Erkennungsperformance auf einem hohen Niveau liegen muss, finden für derartige Qualitätssicherungsaufgaben überwachte maschinellen Lernverfahren (supervised machine learning) Anwendung. Im Bereich des überwachten maschinellen Lernens gibt es eine Vielzahl von KI-Methoden, sowohl konventionelle als auch Deep-Learning-Methoden. Insbesondere das Deep Learning hat aufgrund vielversprechender Ergebnisse in vielen Bereichen von Wissenschaft, Industrie und Alltagsleben mittlerweile stark an Bedeutung gewonnen. Der Erfolg tiefer neuronaler Netze hängt unmittelbar mit der gestiegenen Rechenperformance und insbesondere der Rechenleistungszunahme der High-Performance-Graphik-Karten zusammen, welche eine Berechnung neuronaler Netze solcher Kapazität überhaupt erst möglich machen.

Mit Deep-Learning-Netzen können grundsätzlich sehr gute Erkennungsraten erzielt werden, wenn entweder vortrainierte neuronale Netze verwendet werden, welche auf der Basis von Bildern ähnlicher industrieller Erkennungsaufgaben vortrainiert wurden, oder wenn sehr große Mengen an vorklassifizierten Trainingsdaten zur Verfügung gestellt werden können (sehr kosten- und zeitintensiv). In diesem Beitrag werden innovative Qualitätssicherungslösungen zur automatischen Erkennung verschiedener Fehlerklassen im industriellen Fertigungsprozess beim Kunststoffspritzguss von mikrofluidischen Bauteilen in der Medizintechnik und Makrobauteilen im Automobilbau untersucht und vorgestellt (siehe Abbildung 1).



**Abbildung 1:** Prüfteilbeispiele: mikrofluidisches Bauteil aus dem Bereich der Medizintechnik (links) [1] und Makrobauteile aus der Automobilindustrie (rechts) in Form von einem Reflektorbauteil (oben) und einem LED-Gehäusebauteil (unten) [2].

Für beide untersuchte industrielle Qualitätssicherungsaufgaben be-

steht die Notwendigkeit, eine angepasste Bildverarbeitungs- und Mustererkennungskette sowie die Anwendung leistungstarker KI-Algorithmen mit erhöhten Generalisierungs- und Abstraktionsfähigkeiten zu realisieren. Die Lösungen der untersuchten industriellen Erkennungsaufgaben haben gemeinsam, dass insbesondere innovative vortrainierte Deep-Learning-Netzwerke [3] gute Ergebnisse liefern können. In diesem Beitrag werden die notwendigen Schritte zur Lösung einer automatisierten Qualitätssicherung im Mikrofluidik-Kunststoffspritzguss und im Makrokunststoffspritzguss gegenübergestellt und die verschiedenen Aspekte einer angepassten Bilderfassung und eines Klassifikationsroutinendesigns näher beleuchtet.

Im Kunststoffspritzguss von Makrobauteilen im Automotive wird ein Prüfsystem für die fertigungsintegrierte Prüfung komplex strukturierter Kunststoffbauteile vorgestellt. Das robotergestützte Prüflingshandling ermöglicht sowohl eine vollautomatische Stichproben- als auch eine 100%-Kontrolle und Aussortierung fehlerhafter Bauteile in Abhängigkeit zur gewählten Taktzeit der Spritzgussmaschine. Auf Basis moderner maschineller Lernverfahren wird sowohl die Maßhaltigkeit überprüft als auch die Oberflächenbeschaffenheit auf kleinste Fehler wie Einschlüsse, Blasenbildung, lokale Verformungen oder Farbabweichungen untersucht. Durch den Einsatz adaptiver Prüfmethoden können die Prüfverfahren an neue Bauteilgeometrien, Materialien und Farbmerkmale angepasst werden. Die kurze Prüfzeit ermöglicht einen Echtzeitbetrieb auch bei hohen Durchsatzraten. Damit ist diese Methode im besonderen Maße für den Einsatz im Spritzguss von Makrobauteilen geeignet. Die im Spritzguss hergestellten untersuchten Bauteile kommen in Fahrzeugen zum Einsatz und unterliegen einem hohen Produktionsvolumen bei gleichzeitig kurzen Produktlebenszyklen, was eine schnelle, effiziente, kostengünstige und adaptierbare Lösung notwendig macht. Dank eines speziell entwickelten robotergestützten Bildaufnahmesystems können auch komplexe und transparente Objekte inspiziert werden.

Im Kunststoffspritzguss von mikrofluidischen Bauteilen wurde ein innovatives Inspektionssystem zur fertigungsintegrierten Prüfung von komplex strukturierten mikrofluidischen Kunststoffbauteilen für Lab-on-a-Chip-Anwendungen in der Diagnostik erarbeitet. Diese medizintechnische Anwendung von spritzgegossenen mikrofluidischen

dischen Bauteilen erfordert eine hochpräzise und 100%ige Kontrolle der Produktion. Die optische Qualitätskontrolle wurde durch die Entwicklung eines QC-Prototyps und einer angepassten KI automatisiert realisiert. Auch hier werden Algorithmen aus dem Bereich des maschinellen Lernens zur Auswertung der Bilddaten eingesetzt. Übergeordnetes Ziel war es, die Qualität und Produktivität der gesamten Wertschöpfungskette zu steigern.

## **2 Stand der Technik der Qualitätssicherung mittels Bildverarbeitung und KI in der industriellen Produktion**

Die digitale Bildverarbeitung spielt eine herausragende Rolle in der Qualitätssicherung von Produktionsprozessen. Neben den klassischen Anwendungen ebnete sie auch den Weg für Lösungen im Bereich der Industrie 4.0 [4], [5]. Bei der Oberflächenprüfung werden in der Praxis häufig manuelle Stichprobenprüfungen durchgeführt, die mit einem hohen Zeitaufwand und subjektiven, prüferabhängigen Ergebnissen verbunden sind. Aufgrund immer schnellerer Produktionsprozesse, fortschreitender echtzeitnaher Anforderungen in der Qualitätsanalyse und erheblicher Fortschritte in der Rechen- und Analysetechnik sind manuelle Oberflächenanalysen nicht mehr zeitgemäß, weshalb auch ein schnell fortschreitender Wechsel zu automatisierten Verfahren beobachtet werden kann [6]. Für unterschiedliche Anwendungsbe-reiche existieren bereits verschiedene Methoden zur Oberflächenanalyse unter Verwendung von Bildverarbeitungsmethoden, z.B. die Detektion von Defekten auf Plattenmaterial, die Inspektion von lackierten Oberflächen und die Bildanalyse zur Defekterkennung auf Wafern [7]. Für die Analyse von Oberflächendefekten auf industriell gefertigten Oberflächen werden meist Verfahren der Texturanalyse eingesetzt [8], [9]. Für die Automatisierung von Oberflächeninspektionsaufgaben sind maschinelle Lernverfahren zur Realisierung der Klassifizierung in in-Ordnung (iO) oder nicht-in-Ordnung (niO) bzw. einzelne Fehlerklassen zwingend erforderlich. Beim maschinellen Lernen erkennt der Algorithmus Muster und Regelmäßigkeiten in den ihm zur Verfügung gestellten Beispielen und wendet diese auf praktische Prüfungen an. Während des Lernprozesses wird die Korrelation zwischen Merkma-

len und Klassen der Trainingsobjekte ermittelt, die zur Vorhersage der Klassen von unbekannten Objekten genutzt wird [10]. Neben den klassischen Algorithmen erfährt das sogenannte Deep Learning derzeit einen erheblichen Aufschwung. Das Convolutional Neural Network (CNN) zum Beispiel ist ein tiefes künstliches neuronales Netz, das sich besonders für Bildverarbeitungsaufgaben eignet [11]. Während bei klassischen Verfahren relevante Regionen in Bildern segmentiert und wichtige Merkmale berechnet werden müssen, entfallen diese Zwischenschritte bei CNNs, da sie innerhalb des Algorithmus automatisiert erfolgen.

Deep-Learning-Algorithmen haben in den letzten Jahren bemerkenswerte Ergebnisse erzielt und übertreffen die Fähigkeit traditioneller Methoden, Korrelationen in hochdimensionalen Datensätzen zu finden. Dennoch gibt es einige Nachteile und Einschränkungen bei der Anwendung dieser Algorithmen. Tiefe neuronale Netze benötigen eine extrem große Datenmenge, um eine gute Generalisierungsfähigkeit zu entwickeln und damit gute Ergebnisse zu liefern [12]. Alternativ dazu können vortrainierte CNNs verwendet werden, welche im Idealfall bereits mit großen Bilddatensätzen industriellen Ursprungs vortrainiert wurden.

### **3 Bilderfassung und Datensatzerstellung für die untersuchten industriellen Qualitätssicherungsaufgaben**

In Abbildung 2 sind die für beide industrielle Applikationen erarbeiteten und für die Untersuchungen verwendeten Bildaufnahmeeinrichtungen dargestellt, links im Bild der roboterassistierte Prüfstand in der Kunststoffspritzgussfertigungsanlage zur Prüfung von Makrobau teilen im Automotive und rechts der Prüfstand für die Prüfung von mikrofluidischen Chips für die Medizintechnik. Beide Systeme arbeiten auf Basis optischer Sensoren, unterscheiden sich jedoch stark in der technologischen Umsetzung aufgrund sehr unterschiedlicher Anforderungen im Fertigungsprozess und den zu prüfenden Bauteilen.



**Abbildung 2:** Bildaufnahmeeinrichtungen für die Prüfung von Makrobauteilen im Automobilbau (links) [2] und von mikrofluidischen Chips (rechts).

### **3.1 Bilderfassung und Datensatzerstellung für die Qualitätssicherung von Kunststoff-Spritzgussteilen im Automobilbau**

Zunächst wurden mit verschiedenen Kamerasystemen Voruntersuchungen zur Bildaufnahme durchgeführt, um den Materialcharakteristiken und Reflexionseigenschaften der Prüfteile zu entsprechen und qualitativ hochwertige Bilder gewinnen zu können. Die finale Bildaufnahmeeinrichtung besteht aus einer 5-Megapixel-Kamera mit Auflicht und Durchlicht sowie einem Gehäuse zum Schutz vor Fremdlicht. Das Handling der Prüfteile wurde vollautomatisch mittels eines Knickarmroboters realisiert (siehe Abbildung 2 links). Die Kommunikation mit der Spritzgussmaschine wurde über binäre Signale und ein selbst entwickeltes Protokoll realisiert, um eine hohe Stabilität und Sicherheit zu gewährleisten. Das Beleuchtungssystem wurde optimiert, um einen hohen Kontrast bei der Abbildung kleiner Oberflächendetails und Defekte zu erreichen. Schatten, lokale Reflexionen und lokale Über- und Unterbelichtungen wurden durch eine hochdiffuse Beleuchtungscharakteristik ähnlich einer Dombeleuchtung minimiert.

Für die Untersuchung wurden im Projekt zunächst gemeinsam mit den beteiligten Partnern die Prüfteile festgelegt und Kriterien zur Prüfung erarbeitet sowie ein Fehlerkatalog aufgestellt (Fehlerklassen definiert). Hier konnten insbesondere zwei Fehlerarten herausgearbeitet werden:

zum einen fehlerhafte Maschinenparameter (insbesondere fehlender Nachdruck, falsche Temperatur an der Düse, Defekt an der Spritzgußform) und zum anderen eine fehlerhafte Materialzusammensetzung (insbesondere Beimengung von ungeeignetem Kunststoffgranulat, Farbabweichungen). Als Prüfteile wurden aufgrund der besonderen optischen Herausforderungen ein schwarzes LED-Gehäuse und ein transparentes Reflektorbauteil ausgewählt. Im Ergebnis konnten verschiedene Datensätze der Prüfteile „LED-Gehäuse“ und „Reflektor“ gewonnen werden, auf denen die KI-Algorithmen trainiert wurden, um diese später erfolgreich in den Demonstrator integrieren zu können. Der mit dem Roboter-assistierten Bildaufnahmesystem gewonnene Bilddatensatz besteht aus rund 500 Objektbildern für beide Arten von Prüfteilen (roter Reflektor und schwarzes LED-Gehäuse). Die Musterteile wurden zuvor sowohl während der regulären Fertigung als auch im Rahmen einer gezielten Fehlersimulation gesammelt, indem die Prozessparameter und die Materialzusammensetzung so verändert wurden, dass bewusst fehlerhafte Teile unter kontrollierten Bedingungen produziert werden konnten. Für die Trainingsmenge (100 - 150 Beispiele pro Klasse) wurden repräsentative Musterbilder der Hauptfehler beim Spritzgießen in Form von „Düse zu heiß“, „ohne Nachdruck /zu geringer Nachdruck“ und „falsche Granulatzusammensetzung“ sowie fehlerfreie „Gutteile“ (iO-Teile) für das Prüfteil LED-Gehäuse sowie „Gutteile“, „Defekt Einfall“ und „punktförmige Defekte“ für das Prüfteil Reflektor verwendet. Die deutlich erkennbaren Unterschiede zwischen fehlerfreien und fehlerhaften Teilen ermöglichen es, mit einer relativ kleinen Menge von Musterteilen einen repräsentativen Datensatz für das Training der KI zu erhalten.

### **3.2 Bilderfassung und Datensatzerstellung für die Qualitätssicherung von mikrofluidischen Kunststoff-Spritzgussteilen für die Medizintechnik**

Die hierfür erarbeitete Bildaufnahmeeinrichtung besteht aus einem 12K-Zeilenskenasensor und einem 12M-Pixel-Matrixkemasensor. Die resultierende Bildgröße beträgt 25000 x 9000 Pixel. Das gesamte Bildaufnahmesystem ist in einem Schutzgehäuse untergebracht, das



vor Fremdlicht schützt (siehe Abbildung 2 rechts). Dies ist von großer Bedeutung, da schon kleine Veränderungen in der Beleuchtung zu einer geringeren Erkennungsrate führen könnten. Das Einsetzen der mikrofluidischen Bauteile erfolgt derzeit noch manuell, während die anschließende Bilderfassung und -auswertung automatisch durchgeführt werden. Für jedes zu prüfende Bauteil werden 26 Bilder mit beiden Kameras aufgenommen. Der klassische Basis-Algorithmus betrachtet und verfolgt vordefinierte Stellen auf dem mikrofluidischen Bauteil, wie  $\mu\text{m}$ -große fluidische Kanäle und  $\mu\text{m}$ - bis mm-große Hohlräume, und wertet im Anschluss das Bild aus. Im Bereich vorkommender optischer Unregelmäßigkeiten im fluidischen Kanal werden in einem zweiten nachgelagerten Schritt Bildausschnitte der Abmessungen  $500 \times 500$  Pixel, welche die Unregelmäßigkeiten enthalten, ausgeschnitten und zur automatischen Prüfung an die vortrainierte KI übertragen. Der Ursprung dieser Unregelmäßigkeiten kann von unkritischen Lufteinschlüssen um einen Kanal bis hin zu einem kritischen Partikel im Kanal selbst reichen, der die Funktionsfähigkeit des gesamten Bauteils beeinträchtigen kann und daher als funktionskritisch sicher erkannt werden muss. Die Rohbilder, die Vorschaubilder mit Markierungen und alle gesammelten Ergebnisse werden im Ergebnis in einer NAS- und SQL-Datenbank abgelegt und gespeichert.

Die KI-Erkennungsroutine wurde angelernt mit Teilbildausschnitten der Größe von  $500 \times 500$  Pixeln, die aus dem mikrofluidischen Kanal entnommen und von einem menschlichen Experten vorklassifiziert wurden. Der aufgenommene Datensatz besteht aus insgesamt 2.264 Bildausschnitten der vier Klassen: „Kanal\_sauber“ (499 Objektausschnitte), „Kanal\_mit\_Fließlinie“ (500), „Kanal\_Grat“ (425) und „Kanal\_Partikel“ (840), wobei die Oberklasse „Kanal\_Partikel“ wiederum die drei Partikelklassen: „Partikel\_unkritisch“, „Partikel\_kritisch“ und „Partikel\_unkritisch\_Fluse“ enthält. Eine Differenzierung der verschiedenen Partikelklassen gestaltet sich als schwierig aufgrund der sehr unterschiedlichen Lage der Partikel unterhalb, oberhalb oder im Kanal, welche in einer 2D-Bildaufnahme ohne Tiefeninformation nicht sicher detektiert werden kann.

## 4 Bildverarbeitungs- und Mustererkennungskette

Abbildung 3 zeigt die Bildverarbeitungs- und Mustererkennungskette, die der Lösung jeder Erkennungsaufgabe mit Hilfe des maschinellen Lernens zugrunde liegt und welche die Basis für die aufgezeigten KI-Lösungen bildet.

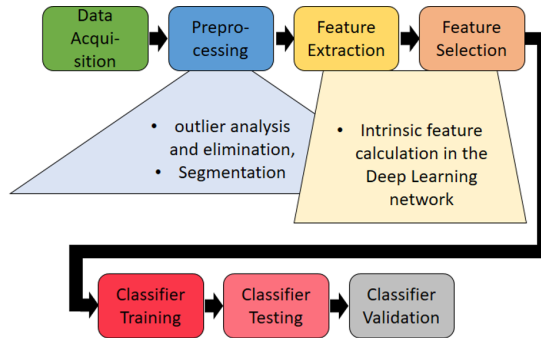


Abbildung 3: Bildverarbeitungs- und Mustererkennungskette.

## 5 KI-Lösung für die Qualitätssicherung von Kunststoff-Spritzgussteilen in der Automobilindustrie

Ein auf industriellen Bilddaten vortrainiertes CNN der Softwarebibliothek Halcon (enhanced CNN) wurde mit dem gewonnenen Datensatz trainiert und optimiert. Es konnten Erkennungsraten (ER) zwischen 95 und 100 % für die verschiedenen Klassen im Laboreinsatz erreicht werden, wobei reduzierte rgb-Bilder der Größe von 500 x 500 Pixeln verwendet wurden.

Die im Labortest erreichte Erkennungsleistung des besten Deep-Learning-Verfahrens (ebenfalls eine vortrainierte Halcon-CNN) lag für die Prüfteile LED-Gehäuse bzw. Reflektor bei einer mittleren Gesamt-ER von 96,22 % mit einer Standardabweichung (Stabw) von 1,92 % bzw. mittleren Gesamt-ER von 97,63 % mit einer Stabw von 1,70 %.

Die erreichbaren Erkennungsleistungen der einzelnen Fehlerklassen im späteren Robotereinsatz in der Fertigungsstraße, d. h. im Industrieinsatz unter realen Umgebungsbedingungen, lagen dann zwischen 90 und 100 %. Die im Industrieinsatz angestrebte und erreichte Klassifikationszeit pro Objekt (ohne Hardware-Handlingzeit) beträgt weniger als 1 ms bei einer mittleren Erkennungsleistung von 90 bis 100 % je nach Einzelklasse. Im Ergebnis konnten damit mit dem finalen Roboter-assistierte System und der auf Industriebildern als Klassifikator vortrainierten CNN der Bildverarbeitungsbibliothek MV-Tec Halcon (Version 18.11) je nach Kunststoffspritzguss-Applikation (Art des Bauteils), Modellparametereinstellung und vorkommenden Fehlerklassen mittlere Gesamterkennungsraten von deutlich größer 90 % erzielt werden.

## **6 KI-Lösung für die Qualitätssicherung von Kunststoffspritzguss-Mikrofluidik-Bauteilen in der Medizintechnik**

Die für diese Aufgabenstellung verwendete Erkennungsroutine arbeitet mit Teilmobdausschnitten der Größe 500 x 500 Pixeln, die vom mikrofluidischen Kanal aufgenommen werden. Das Ziel der Erkennungsroutine war die automatisierte Erkennung von Fehlern des mikrofluidischen Kanals. Teilmobdausschnitte wurden der KI zur Bewertung von Fertigungsfehlern zur Verfügung gestellt. Da der Basisalgorithmus die Kanalverfolgung und Bildausschnitterzeugung bereits realisiert, mussten bei dieser Erkennungsaufgabe keine weiteren Vorverarbeitungsschritte durchgeführt werden. Die Experten-vorklassifizierten Teilmobder der iO- sowie der Fehlerklassen (niO) konnten direkt für das Deep-Learning-Netzwerk zur Berechnung der intrinsischen Merkmale und zum Training verwendet werden.

Es wurde eine dreifach stratifizierte Kreuzvalidierung verwendet, d. h. 2/3 der Objekte (Teilmobder) wurden zum Training und zur Validierung und 1/3 zum Testen verwendet. Aus den drei Durchläufen mit iterativ vertauschten Trainings- und Testpartitionen und der über drei Durchläufe gemittelten Erkennungsrate wurde eine statistisch bessere Vorhersagegenauigkeit ermöglicht. Die vier vortrainierten

neuronalen Netze „compact“, „enhanced“, „alexnet“ und „resnet50“ der Softwarebibliothek Halcon 20.05 [3] wurden in ihrer Eignung für das gegebene Erkennungsproblem näher untersucht. Für die verschiedenen CNN-Varianten wurden unterschiedliche, an die Erkennungsaufgabe angepasste Klassifikatorparameter verwendet. Für die Testergebnisse wurden die mittlere Erkennungsrate [%] und die Standardabweichung [%] berechnet. Die durchschnittlich erreichten Gesamterkennungsraten liegen bei 73,99 % für den vortrainierten CNN „alexnet“, 92,92 % für „compact“, 97,17 % für „resnet50“ und 98,32 % für „enhanced“.

Die erreichbaren Erkennungsleistungen der einzelnen Fehlerklassen im späteren Fertigungseinsatz stehen noch aus, da sich der Finaldemonstrator momentan noch im Aufbau befindet.

## **7 Zusammenfassung der Ergebnisse und Fazit**

Dieser Beitrag zeigt die erfolgreiche Anwendung von vortrainierten Deep-Learning-Netzwerken für intelligente Qualitätssicherungslösungen zur automatischen Erkennung verschiedener Fehlerklassen im industriellen Fertigungsprozess exemplarisch für zwei unterschiedliche Applikationen im Kunststoffspritzguss auf. Die vorgestellten KI-Lösungen zeigen eine erfolgreiche Implementierung der Bildverarbeitungs- und Mustererkennungskette und eine herausragende Leistungsfähigkeit vortrainierter Deep-Learning-Netzwerke (CNNs). Die höhere Generalisierungsfähigkeit und das höhere Abstraktionsvermögen von CNNs ermöglichen die Realisierung von vollautomatisierten Qualitätssicherungsprozessen in der industriellen Fertigung. Für beide Anwendungen konnten bei Optimierung der verwendeten KI mittlere Gesamterkennungsraten größer 95 % erreicht werden.

## **Danksagung**

Das vom Freistaat Thüringen geförderte Projekt „OptoCheck - Neuartiges Verfahren zur Inline-Prüfung von Maßhaltigkeit und

Oberflächenbeschaffenheit an komplexen Bauteilen in Maschinenbau und Automotive“ wurde aus Mitteln der Europäischen Union im Rahmen des Europäischen Fonds für regionale Entwicklung (EFRE) kofinanziert. Das Projekt „Digitalisierung und Robotisierung im Kontext von Industrie 4.0 in der Qualitätskontrolle einer mikrofluidischen Detektionsplattform (QualiMikro)“ wurde durch das BMBF gefördert. Besonderer Dank gilt den fördernden Institutionen, die durch ihre finanzielle Unterstützung die Durchführung der Forschung ermöglicht haben. Die Verantwortung für den Forschungsinhalt liegt bei den Autoren.

## Literatur

1. “Example for a microfluidic component,” 2021. [Online]. Available: <https://www.microfluidic-chipshop.com/>
2. D. Garten, M. Ullrich, J. Hilpert, U. Speck, and K. Anding, “Roboter-gestützte qualitätssicherung in fertigungsprozessen,” in 3. RIS3-Industrieforum, *Smarte Fertigung*, January 2021.
3. Halcon, “comprehensive standard software for machine vision with an integrated development environment,” 2022. [Online]. Available: <https://www.mvtec.com/de/produkte/halcon/>
4. VDMA, *Schlüsseltechnologie für die Automatisierung: Industrielle Bildverarbeitung 2017/18: Anwendungen - Produkte - Bezugsquellen*, 2016.
5. J. Posada, C. Toro, I. Barandiaran, D. Oyarzun, D. Stricker, R. D. Amicis, E. B. Pinto, P. Eisert, J. Döllner, and I. Vallarino, “Visual computing as a key enabling technology for industry 4.0 and industrial internet,” in *IEEE Computer Graphics and Applications*, Vol. 35(2), S. 26-40, 2015.
6. S. Nölling, 2015. [Online]. Available: [https://wiki.zimt.uni-siegen.de/fertigungsautomatisierung/index.php/%C3%9Cberblick\\_zum\\_Stand\\_der\\_Technik\\_in\\_der\\_Oberfl%C3%A4cheninspektion\\_f%C3%BCr\\_Metall-\\_und\\_Faserverbundwerkstoffe](https://wiki.zimt.uni-siegen.de/fertigungsautomatisierung/index.php/%C3%9Cberblick_zum_Stand_der_Technik_in_der_Oberfl%C3%A4cheninspektion_f%C3%BCr_Metall-_und_Faserverbundwerkstoffe)
7. X. Jiang, P. Scott, and D. J. Whitehouse, “Visual computing as a key enabling technology for industry 4.0 and industrial internet,” in *CIRP Annals-Manufacturing Technology*, Vol. 57(1), S. 555-558, 2008.
8. X. Xie, “Visual computing as a key enabling technology for industry 4.0 and industrial internet,” in *ELCVIA Electronic Letters on Computer Vision and Image Analysis*, Vol. 7(3), S. 1-22, 2008.

9. M. Fuß, "Verfahren zur automatisierung der visuellen oberflächeninspektion mit hilfe der bildverarbeitung," 1997, zESS-Forschungsberichte, Dissertation.
10. F. Camastra and A. Vinciarelli, *Machine Learning for Audio, Image and Video Analysis: Theory and Applications*. Springer, 2008.
11. Y. Lecun, Y. Bengio, and H. Geoffrey, "Deep learning," in *Nature*, Vol. 521(7553), S. 436, 2015.
12. G. Marcus, "Deep learning: A critical appraisal," 2018.