

## **In-Situ Qualitätskontrolle an manuellen Arbeitsplätzen durch künstliche Intelligenz**

Jannik STACH, Holger DANDER, Gerd WITT

*Arbeitsgruppe Hybrid Process,  
Lehrstuhl Fertigungstechnik,  
Institut für Produkt Engineering, Fakultät für Ingenieurwissenschaften,  
Universität Duisburg-Essen  
Lotharstraße 1, D-47057 Duisburg*

**Kurzfassung:** Unternehmen stehen heute vor der Herausforderung einer steigenden Wettbewerbsfähigkeit bei gleichbleibendem Qualitätsanspruch. In der Automobilindustrie etwa ist eine 100%-Prüfung hergestellter Produkte die Regel. Das stellt sich bei manuell geprägten Prozessen besonders zeit- und kostenintensiv dar, da jene Tätigkeiten oftmals von Individualität geprägt sind. Der hier vorgestellte Ansatz berücksichtigt eine in-situ Qualitätskontrolle für manuelle Tätigkeiten auf Basis Künstlicher Intelligenz (KI) und ermöglicht eine Fehlererkennung direkt am Entstehungsort, sodass dieser behoben werden kann. Zum Einsatz soll das System bei manuell geprägten Tätigkeiten kommen, bei denen variantenreiche Produkte gefertigt werden. Durch die arbeitsplatznahe Bereitstellung werden Folgefehler vermieden, eine Null-Fehler-Produktion ist die Folge.

**Schlüsselwörter:** Assistenzsystem, Qualitätskontrolle, Digitalisierung, KI, Maschinelles Lernen

### **1. Motivation**

Markt und Wettbewerb stellen Unternehmen vor die Herausforderung immer individuellere und dadurch variantenreichere Produkte herzustellen, aber trotzdem die Qualität bei der Fertigung beizubehalten. Gleichzeitig sollen Produktionszyklen kürzer und Lagerflächen durch Just-in-time-Produktion eingespart werden. (Ustundag & Cevikcan 2017)

Um den Qualitätsanspruch der Kunden gerecht zu werden und nachgelagerte Produktionsketten nicht zum Stillstand zu bringen, ist die Qualität der Produkte von großer Bedeutung. Gerade an manuellen Arbeitsplätzen können durch monotone Aufgaben und Ermüdung schnell Fehler entstehen, die nachgelagerte Produktionsabschnitte oder die Qualität des Endproduktes gefährden. (Stranks 2005)

Aktuelle Qualitätskontrollen werden häufig als zusätzliche, eigenständige Prozesse an bestehende Produktionsketten angehängt. Dadurch entsteht ein neuer Teilprozess der keine Wertschöpfung beinhaltet. Durch den Mehraufwand werden die Produktionszyklen verlangsamt und es können erneut Fehler bei der Qualitätsprüfung entstehen.


Abhilfe soll hier ein Assistenzsystem mit künstlicher Intelligenz schaffen, welches auf Basis moderner Architekturen und Algorithmen entwickelt wurde. Mit diesem System konnte erfolgreich gezeigt werden, dass eine intuitive und effektive in-situ Qualitätskontrolle in Echtzeit möglich ist. Durch die Einbindung in den Arbeitsfluss entstehen für Mitarbeitende kaum Mehraufwände. Außerdem ermöglicht das System durch

die verlässliche Qualitätskontrolle eine Null-Fehler-Produktion, die wirtschaftlich zielführend ist, Folgefehler in der Produktion verhindert und die Mitarbeitenden entlastet.

## 2. Assistenzsystem zur Qualitätskontrolle

Das Assistenzsystem basiert auf einer aktiv lernenden künstlichen Intelligenz die mit einer intuitiven Benutzeroberfläche kombiniert wurde.

Vor Beginn der Entwicklung wurde mit einer vorangehenden Studie die Hardware und Software-Möglichkeiten erfasst und durch unterschiedliche Pugh-Matrizen mit einander verglichen. Bei der Hardware wurden verschiedene optische Komponenten gegeneinander abgewogen, mit denen man die zugrunde liegenden Produkte erfassen kann. Als Ergebnis wurde aus wirtschaftlichen Gründen eine gewöhnliche Webkamera gewählt, welche die nötige Wiederholungsrate besitzt, um in einer Echtzeitumgebung implementiert zu werden. Für den Demonstrator wurde die Logitech C920 HD gewählt. Der Aufbau lässt sich dabei in bestehende Arbeitsprozesse integrieren. Wie in Abbildung 1 zu sehen ist, besteht das Gesamtsystem aus einer fest über dem Arbeitsplatz montierten Kamera, sowie aus einem All-in-One PC, der mit der Kamera verbunden ist. Der Computer übernimmt die Aufgaben der Bildverarbeitung, Klassifizierung und Ergebnisdarstellung. Eine Netzwerkverbindung ist optional möglich, auf die im Ausblick Bezug genommen wird.



**Abbildung 1:** Grafik eines Arbeitsplatzes zur Qualitätskontrolle

Für die Konzeption der Software wurden verschiedene Bildverarbeitungs-bibliotheken verglichen. Auf Basis der Ergebnisse einer erstellten Pugh-Matrix wurde die Bibliothek OpenCV genutzt. Die Bibliothek ermöglicht es die aufgenommenen Bilder in Echtzeit zu analysieren und die zu prüfenden Stellen herauszufiltern. Kombiniert wird die Bibliothek mit Tensorflow der Firma Google Inc. als Framework für das maschinelle Lernen. Tensorflow eignet sich wegen seiner gute Geschwindigkeit, die durch eine

effektive Parallelisierung der Berechnungen auf der Grafikkarte erreicht wird. (Bhardway et al. 2018)

Die neuronalen Netze von Tensorflow ermöglichen, die Merkmale der in Echtzeit aufgenommenen Bildern mit dem trainierten Modell zu verknüpfen und eine Klassifikation der Prüfstellen vorzunehmen. Für diese Anwendung hat besonders das Convolutional Neural Network (CNN) gute Ergebnisse gezeigt. (Guo et al. 2017)

Ein CNN unterscheidet sich von anderen neuralen Netzen vor allem durch die vollständige Verbundenheit der künstlichen Neuronen. Das bedeutet, dass jedes Neuron einer Schicht mit jedem Neuron der folgenden Schicht verbunden ist. Dieser Ansatz eignet sich für Eingabeparameter die als zwei- oder dreidimensionale Matrix dargestellt werden können, sodass er für die erzeugten Bilddaten direkt anwendbar ist. Ein weiterer Vorteil von CNNs bei der Bildverarbeitung ist die geringe Nutzung von Vorverarbeitungsfunktionen und Filtern, wodurch weitere Berechnungszeit eingespart wird. (Sewak et al. 2018)

Für die Klassifikation wird das System vor der Qualitätskontrolle aktiv mit positiven und negativen Beispielen der Prüfteile trainiert. Danach kann das System die Klassifikation von Produkten eigenständig im Prozessablauf durchführen und somit als eine automatische Qualitätskontrolle am Arbeitsplatz genutzt werden. Für ein optimales Ergebnis wurden verschiedene Trainingsmodelle erstellt und mit identischen Datensätzen validiert. Durch eine best-practice Parametrisierung konnte eine gute Klassifizierung, bei geringer Trainingszeit, erreicht werden.

Ergänzt wird die Software durch eine intuitive Benutzeroberfläche, welche es dem Mitarbeitenden ermöglicht sowohl neue Produkte dem System anzutrainieren als auch im laufenden Betrieb die Qualität des Produktes zu überwachen und zu dokumentieren.

### **3. Ergebnis der Machbarkeitsstudie**

Für die Validierung des Assistenzsystems wurde eine Machbarkeitsstudie von Kabelsträngen aus der Automobilbranche durchgeführt. Ein besonders hoher Wert wurde dabei auf die Wirtschaftlichkeit und Effektivität des Systems gelegt. Zudem sollten die Systemgrenzen hinsichtlich der Trennungsschärfe aufgezeigt werden.

Als Testobjekt wurde ein Kabelsatz verwendet, der im Bereich des Radkastens aktueller Automobilmodelle zum Einsatz kommt. In Abbildung 2 werden die wichtigen Stellen hervorgehoben, die vom Assistenzsystem auf Produktionsfehler untersucht wurden. Der Leitungssatz besteht aus drei Einzelleitungen, sieben Connectoren, vier Scharnieren und neun Tüllen, die entsprechend der Abbildung gekennzeichnet sind.

Bei der Studie wurden sowohl fehlerfrei gefertigte Teile (IO) und fehlerbehaftete Teile (NIO) vom System getestet. Anschließend wurde die Klassifizierung der KI mit dem tatsächlichen Zustand der zu analysierenden Bauteilstelle verglichen. Dabei wurden im Vorfeld drei Systemzustände definiert:

IO: Das System bewertet den Zustand der Prüfstelle als richtig


NIO: Das System bewertet den Zustand der Prüfstelle als nicht richtig

N/A: Das System kann keine verlässliche Aussage zu der Prüfstelle treffen

Letztgenannter Zustand trifft ein, wenn das System eine Entscheidung mit einer wahrscheinlichen Gruppenzugehörigkeit von unter 85% trifft oder wenn zu wenig Trainingsdaten für eine eindeutige Entscheidungsfindung vorhanden sind. Dieser Zustand be-

darf demnach einen manuellen Eingriff, der dazu führt, dass das System mit den daraus gewonnenen Erkenntnissen zusätzlich lernt. Demnach ist es ein zu erwartender Systemzustand, dessen Eintreten als korrekt bewertet wird.

Vor der Durchführung der Prüfgenauigkeit wurde das neuronale Netz mit 100 Bildern von entsprechenden Prüfstellen trainiert. Das Erzeugen der Bilddaten hat dabei im Durchschnitt 30 min in Anspruch genommen. Das anschließende, einmalige Training dauerte im Durchschnitt 73 min und bedarf keinem personellen Eingriff.



**Abbildung 2:** Kabelstrang der Machbarkeitsstudie

Insgesamt wurden über 400 Wiederholungen der Prüfung an den in Abbildung 2 markierten Stellen durchgeführt. Mit einer Fehlerquote von 5,95% liegt das System somit im Grenzbereich einer Null-Fehler-Produktion. Neben der geringen Fehlerquote ist ebenfalls der Detailgrad hervorzuheben, bei dem schon kleinste Veränderungen am Testobjekt zu einer richtigen Klassifikation eines fehlerhaften Produktionsteils geführt haben. So konnte beispielsweise das Einrasten eines Klipps mit einem Detaillierungsgrad von < 5 mm zu einer korrekten Klassifikation führen.

#### 4. Diskussion und Ausblick

Das System wurde zunächst als soziotechnischer Demonstrator für den Einsatz an manuellen Arbeitsplätzen konzipiert und kann derzeit noch nicht im Produktionsgeschehen eingebunden werden.

Das Training des Systems durch Erzeugung und Bereitstellung von Bilddaten erfolgt bisher manuell und besitzt daher das Potential für Fehler. Durch eine flexible Anzahl an Trainingsdaten können bessere Klassifizierungsdaten erreicht werden. Allerdings besteht dadurch auch das Risiko für ein Over- bzw. Underfitting, wodurch die Ergebnisse auch verschlechtert werden könnten. Demnach ist eine Analyse geboten, die die optimale Anzahl von Trainingsdaten eruiert.

Zudem kann sich bis heute eine Änderung der Umgebungsfaktoren negativ auf die Klassifizierung auswirken. Unterschiedliche Tageszeiten oder Wetterverhältnisse können vor allem bei reflektierenden Prüfteilen das erfasste Prüfbild verändern, was sich auf die Qualitätskontrolle auswirken kann.

Besonders in manuellen Fertigungsprozessen mit großvolumigen Teilen kann es durch starke Bewegungen am Arbeitsplatz dazu kommen, dass unscharfe Bild zu einer falschen Klassifikationen führen. Aber durch eine Autofokusfunktion der Kamera werden kleine Störfaktoren systemseitig bereits kompensiert.

Das Assistenzsystem lässt sich in der Zukunft in unterschiedlichen Bereichen verbessern oder erweitern. Die bereits erörterten Probleme durch sich ändernde Umgebungsfaktoren könnten durch Vorverarbeitungsalgorithmen reduziert werden, indem die Bilder vor der Klassifikation durch eine simulierte Lichtquellen vereinheitlicht werden. Diese Operationen sind aber Berechnungsintensiv, sodass die Echtzeit-eigenschaft des Systems dabei mit Berücksichtigt werden muss.

Für eine neue Funktion könnte die optionale Netzwerkverbindung des Computers genutzt werden, um mehrere Prüfstationen mit einem gemeinsamen Netzwerk zu verbinden. Durch eine zentrale Kommunikationsschnittstelle könnten die an den einzelnen Arbeitsplätzen erhobenen Daten gebündelt und aufbereitet werden. Auf der Basis dieser Daten könnten dann Statistiken erstellt werden, die neue Erkenntnisse und Korrelationen hervorbringen, um Produktionsprozesse zu optimieren.

## 5. Literatur

- Bhardwaj, A., Di, W., & Wei, J. (2018). *Deep Learning Essentials: Your hands-on guide to the fundamentals of deep learning and neural network modeling*. Packt Publishing Ltd.
- Guo, T., Dong, J., Li, H., & Gao, Y. (2017, March). Simple convolutional neural network on image classification. In *2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA)* (pp. 721-724). IEEE.
- Sewak, M., Karim, M. R., & Pujari, P. (2018). *Practical Convolutional Neural Networks: Implement Advanced Deep Learning Models Using Python*. Packt Publishing Ltd.
- Stranks, J. (2005). *Stress at work*. Routledge.
- Ustundag, A., & Cevikcan, E. (2017). *Industry 4.0: managing the digital transformation*. Springer.



Gesellschaft für  
Arbeitswissenschaft e.V.

## Arbeit HUMAINE gestalten

67. Kongress der  
Gesellschaft für Arbeitswissenschaft

Lehrstuhl Wirtschaftspsychologie (WiPs)  
Ruhr-Universität Bochum

Institut für Arbeitswissenschaft (IAW)  
Ruhr-Universität Bochum

3. - 5. März 2021

---

## GfA-Press

---

**Bericht zum 67. Arbeitswissenschaftlichen Kongress vom 3. - 5. März 2021**

**Lehrstuhl Wirtschaftspsychologie, Ruhr-Universität Bochum  
Institut für Arbeitswissenschaft, Ruhr-Universität Bochum**

Herausgegeben von der Gesellschaft für Arbeitswissenschaft e.V.  
Dortmund: GfA-Press, 2021  
ISBN 978-3-936804-29-4

NE: Gesellschaft für Arbeitswissenschaft: Jahresdokumentation

Als Manuskript zusammengestellt. Diese Jahresdokumentation ist nur in der Geschäftsstelle erhältlich.

Alle Rechte vorbehalten.

© **GfA-Press, Dortmund**

**Schriftleitung: Matthias Jäger**

im Auftrag der Gesellschaft für Arbeitswissenschaft e.V.

Ohne ausdrückliche Genehmigung der Gesellschaft für Arbeitswissenschaft e.V. ist es nicht gestattet:

- den Kongressband oder Teile daraus in irgendeiner Form (durch Fotokopie, Mikrofilm oder ein anderes Verfahren) zu vervielfältigen,
- den Kongressband oder Teile daraus in Print- und/oder Nonprint-Medien (Webseiten, Blog, Social Media) zu verbreiten.

Die Verantwortung für die Inhalte der Beiträge tragen alleine die jeweiligen Verfasser; die GfA haftet nicht für die weitere Verwendung der darin enthaltenen Angaben.

**Screen design und Umsetzung**

© 2021 fröse multimedia, Frank Fröse

[office@internetkundenservice.de](mailto:office@internetkundenservice.de) · [www.internetkundenservice.de](http://www.internetkundenservice.de)