

# Steigerung der Produktsicherheit durch den Einsatz von Deep Learning in der manuellen Montage

Johanna Gerlach<sup>1\*</sup>, Alexander Riedel<sup>1</sup> und Frank Engelmann<sup>1</sup>

<sup>1</sup> Ernst-Abbe-Hochschule Jena, Deutschland

\* Korrespondenz: [Johanna.Gerlach@eah-jena.de](mailto:Johanna.Gerlach@eah-jena.de)

**Kurzfassung.** Produktfehler zu vermeiden hat in vielen Industriezweigen hohe Priorität. Eine Möglichkeit Fehler zu reduzieren, liegt in der Einbindung von Deep Learning in den Produktionsprozess. Fehler könnten automatisiert detektiert und entsprechende Maßnahmen eingeleitet werden. Im Forschungsprojekt wurde untersucht, inwiefern sich Montagefehler durch den Einsatz von Deep Learning reduzieren lassen.

Dazu wurde eine Baugruppe auf zwei Arbeitsplätzen montiert, welche sich nur hinsichtlich des eingesetzten Assistenzsystems (papierbasierte Anweisung vs. digitales System mit Deep Learning) unterscheiden. Dabei wurden alle auftretenden Montagefehler aufgezeichnet. Die Ergebnisse zeigen eine Fehlerreduktion von 45% und belegen das hohe Fehlervermeidungspotenzial durch den Einsatz von Deep Learning.

## 1. Einleitung

In bestimmten Industriezweigen, z.B. in der Medizintechnik, dem Explosionsschutz oder der Raum- und Luftfahrtindustrie, können schon aus kleinen Produktfehlern erhebliche Schäden resultieren. So kann bei einem explosionsgeschützt ausgelegten Produkt bereits eine fehlende Schraube zu einem Zünddurchschlag und damit zu einer verheerenden Explosion führen.

Produktfehler zu vermeiden hat in diesen Industriezweigen eine sehr hohe Priorität, sodass umfangreiche Qualitätssicherungsmaßnahmen notwendig sind. In vielen Fällen, insbesondere im Rahmen von Sichtprüfungen, wird die Qualitätssicherung von Menschen durchgeführt, deren Fähigkeiten Fehler zu erkennen zeitlich sowie personenbezogen stark variieren können.

Eine Möglichkeit, die Gefahr durch menschliche Fehler zu reduzieren, liegt in der Einbindung von Deep-Learning-Modellen in den Produktionsprozess. Indem Fehler bereits während des Herstellprozesses automatisiert detektiert und entsprechende Maßnahmen eingeleitet werden, könnten Produktfehler deutlich reduziert werden. Im vorliegenden Forschungsprojekt wurde daher untersucht, inwiefern sich Montagefehler durch den Einsatz eines Deep-Learning-Modells reduzieren lassen.

## 2. Methoden

Zunächst wurden zwei Arbeitsplätze zur Montage einer explosionsgeschützten Leuchte aufgebaut, welche sich lediglich hinsichtlich des eingesetzten Assistenzsystems unterscheiden. Während auf dem ersten Arbeitsplatz eine papierbasierte Arbeitsanweisung Verwendung fand (AP1), beinhaltete der zweite Arbeitsplatz ein umfangreiches digitales Werkerassistenzsystem (AP2), siehe Abbildung 1.

Im Zentrum des digitalen Assistenzsystems steht eine digitale Arbeitsanweisung, welche die Werker\*innen Schritt für Schritt durch den Montageprozess führt. Über eine auf Deep Learning basierende Objekterkennung werden die einzelnen Montageschritte detektiert, sodass die Arbeitsanweisung selbstständig in den jeweils nächsten Arbeitsschritt weiterschaltet. Als weitere Hilfestellung wurde ein Pick-by-Light-System integriert, welches die im aktuellen Arbeitsschritt zu greifenden Teile aufzeigt. Die einzelnen Module sind jeweils mit einem industriellen Raspberry Pi verknüpft und kommunizieren über das MQTT-Netzwerkprotokoll miteinander.

Zur Erfassung des Werkstückstatus wurde das Objekterkennungsmodell YOLOv4 [cf. 1] eingesetzt. Das Training wurde auf einer Nvidia GeForce 1650 Super GPU unter Verwendung des Darknet Frameworks [cf. 2] durchgeführt. Das Modell wurde auf insgesamt 41 Objektklassen mit durchschnittlich je 134 Repräsentationen in den Trainingsdaten trainiert. Auf den entsprechenden Trainingsdaten wurde nach sechs Trainingsepochen eine Mean Average Precision @ 50% IoU von 99.81% erreicht. Für die Modellinferenz wird ein Nvidia AGX Xavier Embedded System eingesetzt, auf dem das YOLOv4 Modell unter TensorRT Optimierung in Echtzeit lauffähig ist.



**Abbildung 1:** Konventioneller Montagearbeitsplatz mit papierbasierter Arbeitsanweisung (links) und Montagearbeitsplatz mit Pick-by-Light-System, Objekterkennung und digitaler Arbeitsanweisung (rechts)

An beiden Arbeitsplätzen montierten jeweils 12 Versuchspersonen über eine Dauer von 8 Stunden jeweils mindestens 30 Baugruppen. Der Montageprozess wurde kontinuierlich überwacht und alle auftretenden Montagefehler manuell aufgezeichnet. Vorab wurden dazu mittels THERP (Technique for Human Error Rate Prediction) [cf. 3] 70 potentielle Fehlerzustände identifiziert.


### 3. Ergebnisse

Für eine höhere Interpretierbarkeit wurden die identifizierten Fehler gemäß der Richtlinie VDI 4006 Blatt 2 [4] in die Kategorien Unterlassungsfehler (U), Ausführungsfehler (A), Verwechslungsfehler (V) und Quantitativer Fehler (Q) eingeteilt, siehe Tabelle 1.

**Tabelle 1:** Einteilung der potentiellen Fehler in vier Fehlerkategorien

Fehlerart	U	A	V	Q
Absolute Anzahl	18	27	9	16
Relativer Anteil	25%	39%	13%	23%

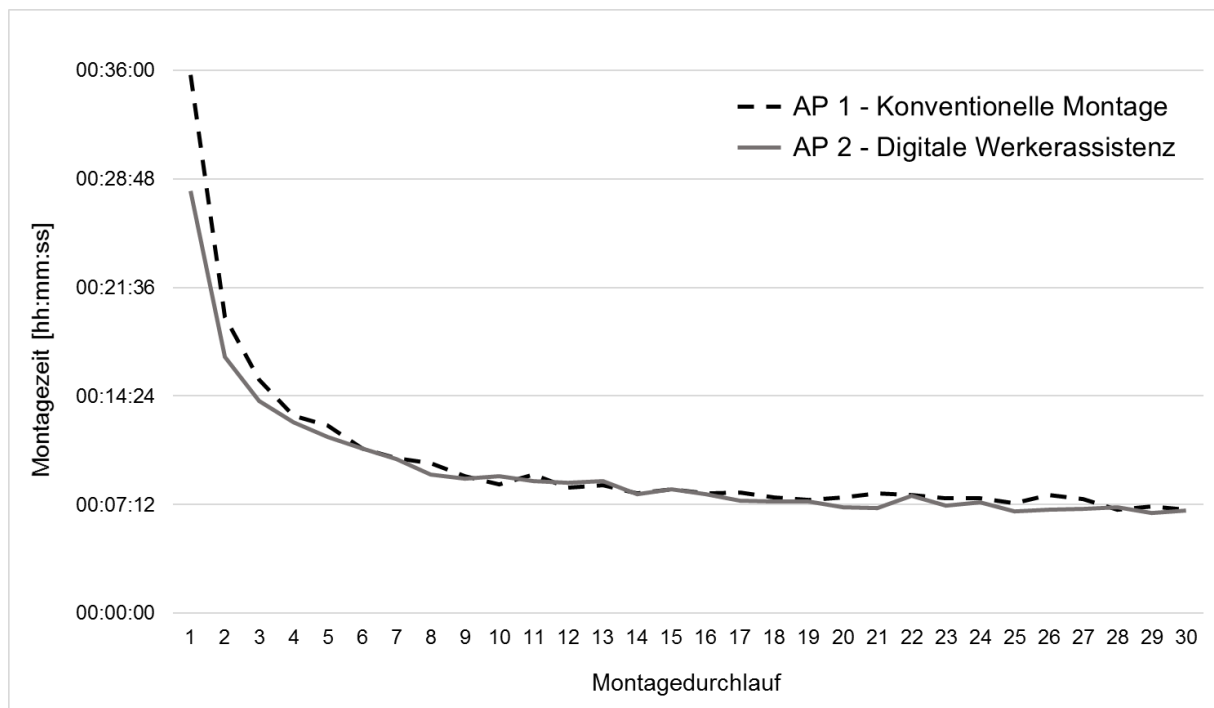
Die Gesamtzahl der Fehler während 30 durchgeführter Montagen sinkt von durchschnittlich 16,4 bei konventioneller Montage auf 9,1 bei digital assistierter Montage. Dies entspricht einer Fehlerreduktion von 45%. Betrachtet man die Anzahl der Fehler pro Kategorie wird außerdem deutlich, dass bei Montagen an AP2 in drei von vier Fehlerkategorien weniger Fehler auftreten als an AP1, siehe Abbildung 2. Insbesondere Unterlassungsfehler (62% weniger), Ausführungsfehler (41% weniger) und quantitative Fehler (38% weniger) werden durch das Montageassistenzsystem wirksam verhindert. Zwar treten Verwechslungsfehler am AP2 häufiger auf als am AP1, aufgrund der sehr niedrigen absoluten Fehlerzahlen (0,6 vs. 1,0) ist dieser Effekt jedoch vernachlässigbar.

**Abbildung 2:** Anzahl der Montagefehler pro Kategorie (U = Unterlassungsfehler, A = Ausführungsfehler, V = Verwechslungsfehler, Q = Quantitativer Fehler)

Die Interpretation der Ergebnisse zeigt, dass Fehler durch Auslassung aktiv verhindert werden, da das System die Ausführung des nächsten Arbeitsschrittes nur dann zulässt, wenn der Abschluss des aktuellen Arbeitsschrittes visuell erkennbar ist. Der allgemein kleinere Interquartilsbereich am AP2 deutet auf eine geringere statistische Streuung der Fehlerzahl in dieser Gruppe und damit auf eine stabilere Montageumgebung hin.

Den Einfluss des digitalen Assistenzsystem auf die Montagedauer zeigt Abbildung 3. Durch den Einsatz des Systems lässt sich die durchschnittliche Montagezeit von 10 Minuten und 1 Sekunde auf 9 Minuten und 23 Sekunden (- 6,4 %) reduzieren. Insbesondere in der Anlernphase (Montage 1 bis 10) zeigt sich, dass die Proband\*innen deutlich geringere Montagezeiten erzielten (- 9,2 %). Da sich die Untersuchung auf die ersten 30 Montagen beschränkt bleibt jedoch unklar, welchen Einfluss das digitale Assistenzsystem auf die sich langfristig einstellende Montagezeit hat. Da sich die Differenz zwischen AP1 und AP2 bereits in den letzten

zehn Montagen annähert (- 5,9 %) ist zu vermuten, dass die Montagezeit langfristig nicht signifikant reduziert werden kann. Dennoch zeigt sich, dass eine geringere Fehlerrate nicht mit einer erhöhten Montagedauer einhergehen muss.



**Abbildung 3:** Durchschnittliche Montagezeit über 30 Montagen

## 4. Ausblick

Insgesamt zeigt das vorliegende Forschungsvorhaben ein hohes Fehlervermeidungspotenzial durch den Einsatz von Deep-Learning-Modellen in der manuellen Montage, ohne dass sich die Montagedauer erhöht. Da die aufgezeichneten Daten die relative Position jedes sichtbaren Bauteils zu jedem Zeitpunkt des Montageprozesses beinhalten, bestehen außerdem große Potenziale in Bezug auf die Rückverfolgbarkeit.

Der wirtschaftliche Wert des vorgestellten Systems sowie die Akzeptanz und Anwendbarkeit in einer realen Produktionsumgebung sind bislang noch unklar und sollten durch weitergehende Analysen ermittelt werden. Darüber hinaus sind rechtliche Aspekte je nach lokaler Gesetzgebung zu klären.

### Datenverfügbarkeit

Aufgrund einer Verschwiegenheitsvereinbarung mit dem produktstellenden Unternehmen, können die Daten nicht zur Verfügung gestellt werden.

### Interessenskonflikte

Seitens der Autor\*innen bestehen keinerlei Interessenkonflikte.

## Literaturverzeichnis

1. Bochkovskiy, Alexey; Wang, Chien-Yao; Liao, Hong-Yuan Mark (2020): YOLOv4: Optimal Speed and Accuracy of Object Detection. <https://arxiv.org/pdf/2004.10934.pdf> [02.02.22].
2. Redmon, Joseph (2016): *Darknet: Open Source Neural Networks in C*. <http://pjreddie.com/darknet/> [02.02.2022].
3. Kirwan, Barry (1994): *A Guide to Practical Human Reliability Assessment*. London: Taylor & Francis.
4. VDI 4006 Blatt 2 (2015): *Menschliche Zuverlässigkeit - Methoden zur quantitativen Bewertung menschlicher Zuverlässigkeit*. Düsseldorf: VDI-Verlag.