



Künstliche Intelligenz für robuste Bildverarbeitung

Wie KI bei der Erkennung von Schweißpunkten hilft

Künstliche Intelligenz gilt als Schlüsseltechnologie für Industrie 4.0 und birgt als solche ein erhebliches Potenzial für das produzierende Gewerbe in Deutschland. Zu den relevantesten Anwendungen in diesem Bereich zählen die Automatisierung von Fertigungs-, Montage- und Prüfprozessen mittels maschinellern Sehen. IconPro, ein Spin-off der RWTH Aachen, zeigt, dass die KI-basierte Bilderkennung schon heute zuverlässig in industriellen Anwendungen arbeitet.

Markus Ohlenforst, Edgar Dietrich

Dabei werden computergestützte Lösungen für Aufgabenstellungen entwickelt, deren Anforderungsprofile üblicherweise eher den Fähigkeiten des menschlichen visuellen Systems entsprechen. In diesem Zusammenhang gelten Deep-Learning-Verfahren als ein Mittel der Wahl, bei dem künstliche neuronale Netze mit einer Vielzahl an Schichten, sogenannten Hidden Layers, zum Einsatz kom-

men. Voraussetzungen sind in der Regel eine ausreichende Menge an Trainingsdaten sowie entsprechende Rechenkapazitäten der für das Training und die Auswertung genutzten Hardware. Alternativ lässt sich in manchen Fällen auch auf bereits vortrainierte Algorithmen zurückgreifen. Dann lassen sich hochkomplexe Problemstellungen lösen, für die sich mit klassischen regelbasierten Algorithmen keine oder nur sehr

aufwendige robuste Lösungen entwickeln lassen.

In der Produktion wird Bildverarbeitung vor allem für die Automatisierung der Montage mit Industrierobotern sowie für optische Prüfprozesse in der Qualitätssicherung eingesetzt.

Eine typische Aufgabe in der Robotik ist die Aufnahme eines Werkstücks, um es anschließend in einer bestimmten Pose zu

montieren oder in einer Bearbeitungsmaschine abzusetzen. In vielen Fällen ist die Ausführung einer immer gleichen Bewegung dafür nicht ausreichend. Stattdessen ist es notwendig, dass der Roboter mittels Bildverarbeitung auf variable Anfangsposen der Objekte reagieren kann. Mithilfe dreidimensionaler Bildinformationen, basierend auf Kamera- und gegebenenfalls Entfernungssensoren, kann das sogenannte „Griff in die Kiste“- oder „Pick-and-Place“-Problem gelöst werden.

Zur Qualitätssicherung werden heute mehr und mehr industrielle Bildverarbeitungssysteme verwendet, die in der Serienproduktion an der Produktionslinie installiert werden können und teils Tausende Teile pro Minute zuverlässig und wiederholbar prüfen. Auch bei der Produktion kleinerer Stückzahlen bietet die industrielle Bildverarbeitung aufgrund der erreichten Genauigkeit und Wiederholbarkeit hervorragende Ergebnisse bei quantitativen Messungen von strukturierten Szenen. In Kombination mit der entsprechenden Auflösung und Optik können Details erkannt werden, welche für das menschliche Auge nicht oder nur schwer sichtbar sind. Maschinelle optische Prüfungen machen somit nutzerunabhängiger und bergen potenziell weniger Fehler.

Varianzen in den Bilddaten sind eine große Herausforderung

Eine hohe Zuverlässigkeit kann bei herkömmlichen industriellen Bildverarbeitungssystemen jedoch nur bei konsistenten und ausreichend gut gefertigten Werkstücken sowie Randbedingungen gewährleis-




Bild 1. Beispielhafter Ausschnitt der gelabelten Bilddaten von Schweißpunkten (©Iconpro)

tet werden. Dies hängt damit zusammen, dass die Auswertung regelbasierte Algorithmen vorsieht, welche durch das Hinzufügen von Ausnahmeregeln aufgrund von zu erwartenden Inkonsistenzen oder Schwankungen der Bilddaten bzw. Werkstücke schwerfällig werden.

Die Verifizierung der Endmontage von Bauteilen stellt ein Beispiel dar, das typischerweise aufwendig zu implementieren ist. Grund dafür ist die Vielzahl an variierenden Randbedingungen wie Beleuchtung, Krümmung, Sichtfeld oder Farbwechsel, die für eine Maschine in der Regel nur schwer konstant zu halten sind.

Bestimmte resultierende Varianzen im Erscheinungsbild des Werkstücks bzw. des Prüflings, z.B. in Bezug auf Drehungen, Skalierungen sowie Perspektiven, werden dabei noch toleriert, wobei jedoch insbesondere schlechtere Bildqualitäten oder kom-

plexe Oberflächentexturen zu kritischen Problemen führen können. Differenzen oder Anomalien in den Bilddaten können in diesem Zusammenhang u.a. in falschen Prüferentscheidungen resultieren. Das Kernproblem im Hinblick auf herkömmliche industrielle Bildverarbeitungssysteme ist somit, dass sie nicht zwischen „äußeren“ Schwankungen der Bilddaten und funktionalen bzw. qualitativen Abweichungen der Prüfobjekte unterscheiden können.

Im Gegensatz zur klassischen Bildverarbeitung ist der Mensch dazu in der Lage, diese Unterscheidungen zu erlernen und vorzunehmen. Auch wenn der Mensch Informationen langsamer verarbeitet, besteht seine Stärke darin, diese zu abstrahieren und vor einem allgemeineren Hintergrund zu beurteilen. In Anwendungsfällen, in denen es um die qualitative Interpretation von komplexen, nicht strukturierten, d.h. signifikant variierenden Bilddaten geht, ist die menschliche Prüfung daher gemeinhin die bessere Wahl.

Beispielsweise ist der Mensch bei der Betrachtung von schwer erkennbaren Zeichen oder Markierungen oder von komplexen Oberflächen bzw. kosmetischen Oberflächendefekten herkömmlichen Bildverarbeitungssystemen überlegen.

Deep Learning beim Erkennen von Schweißpunkten

Mithilfe von Deep-Learning-Modellen lassen sich die kognitiven menschlichen Fähigkeiten teilweise auf maschinelle Bildverarbeitungssysteme übertragen. Auf diese Weise kann die abstrahierende, lernende und qualitative Interpretation von »




Bild 2. Über die Anzahl der Trainingsepochen nimmt die Genauigkeit der Bildererkennung zu. (© Iconpro)




Bild 3. Beispiele für richtige und falsche Klassifizierungen von Schweißpunkten (© Iconpro)

Bilddaten mit ihrer Robustheit gegenüber Varianzen mit der Geschwindigkeit und Wiederholbarkeit industrieller Bildverarbeitungssysteme vereint werden.

Das folgende Beispiel zeigt, wie gut sich bestehende Deep-Learning-Programmiersbibliotheken für die Klassifizierung von Bildern im Rahmen der visuellen Bauteilprüfung nutzbar machen lassen:

Es handelt sich um ein Klassifizierungsproblem, welches einem realen industriellen Anwendungsfall entspringt. Das Ziel war es, für Bildsegmente eines optischen Messdatensatzes zu entscheiden, ob darauf ein Schweißpunkt zu sehen ist oder nicht. Üblicherweise muss dieser Prozess für die im Anschluss folgende klassische Bildverarbeitung manuell vom menschlichen Bediener der Auswertesoftware für eine Vielzahl von Bildsegmenten durchgeführt werden.

Als Ausgangspunkt des Pilotprojekts lagen Hunderte von Bildern mit Schweißpunkten und ohne Schweißpunkte vor, die ebenfalls entsprechend gelabelt waren, d.h. die Information, ob darauf ein Schweißpunkt zu sehen ist, lag zusätzlich für jedes Bild vor.

Bild 1 zeigt Beispiele der vorliegenden Bilder mit beiden Labels bzw. Klassen. Mithilfe dieser Daten wurde ein künstliches neuronales Netz trainiert.

Dabei handelte es sich um ein faltendes neuronales Netz („Convolutional Neural Network“), d.h. eine spezielle Art künstlicher neuronaler Netze, die sich insbesondere für die maschinelle Verarbeitung von Bild- und Audiodaten eignet. Die Implementierung fand in der Programmiersprache Python statt, wobei die Deep-Learning-Bibliothek TensorFlow eingesetzt wurde.

Das Training des Netzes mit den Trainingsdaten und das Testen des Netzes mit

den von den Trainingsdaten abweichenden Testdaten hat über die steigende Anzahl der Trainingsiterationen die hier rechts gezeigten Genauigkeiten ergeben. Man sieht, dass die Genauigkeit des Netzes, d.h. der Anteil der richtig klassifizierten Bilder mit den Klassen „Schweißpunkt“ und „Kein Schweißpunkt“, über den Trainingsiterationen ansteigt. Für die Testdaten, welche das Netz zuvor nicht gesehen hat, ergab sich zum Ende eine Genauigkeit von knapp 99 Prozent (Bild 2).

Testbilder zeigen, dass diese vom Netz nach dem Training richtig klassifiziert wurden (Bild 3). Es sind zwei Bilder mit Schweißpunkten hervorgehoben. Diese sind selbst für das menschliche Auge nicht einfach als solche zu erkennen. Daneben findet sich ein Testbild, das vom Netz falsch klassifiziert wurde. Dieses Bild wurde als „Schweißpunkt“ gelabelt, allerdings vom Netz als „Kein Schweißpunkt“ klassifiziert. Eine genauere Betrachtung des Bildes mit dem menschlichen Auge lässt Zweifel daran aufkommen, dass das Bild als „Schweißpunkt“ richtig gelabelt wurde, so dass das Netz möglicherweise richtig lag.

Obwohl sich diese Tatsache in dem Anwendungsbeispiel nicht abschließend klären ließ, lässt sich zusammengefasst sagen, dass der Proof-of-Concept erfolgreich ausgefallen ist, nur wenige Wochen Entwicklungsarbeit gekostet hat und sich leicht auf ähnliche Problemstellungen übertragen ließe. Der Deep-Learning-Algorithmus zur Schweißpunkterkennung wird inzwischen von den Weißlicht-Scanner-Systemen „Blaze600“, „WLS400“ und „qFlash“ der Firma Hexagon Manufacturing Intelligence angewandt.

Den genannten Vorteilen des Deep Learning stehen Nachteile beim präzisen

INFORMATION & SERVICE

LITERATUR

- **Schuth, M.; Wassili, B.:** Handbuch optische Messtechnik. praktische Anwendungen für Entwicklung, Versuch, Fertigung und Qualitätssicherung. Carl Hanser Verlag, 2017
- **Weik, H.; Werner, K.; Immel, M.:** Galvanikgestelle bestücken mit dem Griff-in-die-Kiste. JOT Journal für Oberflächentechnik 9/2018, S. 84–85
- **Zeng, A. et al.:** Robotic pick-and-place of novel objects in clutter with multi-affordance grasping and cross-domain image matching. IEEE International Conference on Robotics and Automation (ICRA), 2018
- **Liangzhi Li; Kaoru Ota; Mianxiong Dong:** Deep learning for smart industry: Efficient manufacture inspection system with fog computing. IEEE Transactions on Industrial Informatics 10/2018, S. 4665–4673

AUTOREN

Markus Ohlenforst und **Edgar Dietrich** sind die Geschäftsführer der Iconpro GmbH mit Sitz in Aachen.

KONTAKT

Markus Ohlenforst
T 0241 41259946
markus.ohlenforst@iconpro.com

quantifizierenden Messen und messtechnikgestützten Ausrichten von Teilen gegenüber, wofür sich herkömmliche Bildverarbeitungssysteme in der Regel besser eignen.

Vergleich von Deep Learning mit klassischer Bildverarbeitung

Idealerweise werden die beiden Verfahrensarten kombiniert, zum Beispiel wie bei der gezeigten Deep-Learning-Klassifizierung von Bildsegmenten mit oder ohne Schweißpunkt, die im Anschluss selektiv durch herkömmliche Bildverarbeitung quantitativ ausgewertet werden. Dem präzisen Ausrichten von Teilen mittels herkömmlicher Bildverarbeitung kann vorher die richtige Auswahl und roboterbasierte Aufnahme des passenden Teils durch den „Griff in die Kiste“ mithilfe von Deep Learning vorangehen. Gleiches gilt für eine sich gegebenenfalls anschließende qualitative Prüfung auf Vollständigkeit oder auf Defek-

ten, welche möglichst viele Varianzen beinhalten sollten, statt eine Vielzahl von Regeln, Filtern und Auswertelgorithmen für mögliche Fallunterscheidungen zu programmieren. Der Schwerpunkt der Entwicklung liegt damit auf dem Trainieren und Validieren des Algorithmus und nicht auf seiner Erstellung (Tabelle 1).

Lernende Bildverarbeitung kann komplexe Prüfungen übernehmen

Deep-Learning-Verfahren für die Bildverarbeitung eignen sich besonders gut für komplizierte Prüfverfahren in der Produktion, die robust gegenüber Schwankungen oder Anomalien in den Bilddaten sein müssen und qualitative oder diskrete Messgrößen auswerten.

Künstliche neuronale Netze befähigen zur Automatisierung von Prozessen, für welche sich bislang keine oder nur sehr schwer programmierbare Lösungen finden ließen. Auf diese Weise können Fehlerraten

Klassische Bildverarbeitung	Kombination	Deep Learning (Auch bei komplexem / variablem Aussehen:)
quantifizierendes Messen	quantifizierendes Messen und Defekterkennung	Defekterkennung
Barcodelesen	optische Zeichenerkennung	Segmentierung
Vollständigkeitsprüfungen	präzise Merkmalslokalisierung	Vollständigkeitsprüfung
Positionsregelung	Objekte / Merkmale zählen	Merkmalslokalisierung
		Zeichenerkennung

Tabelle 1. Übliche Kategorien von Problemstellungen für Bildverarbeitung in der Produktion und der sinnvolle Einsatz sowie die Kombination von herkömmlichen Verfahren und Deep Learning

te des Bauteils oder der Baugruppe.

Ein weiterer wichtiger Aspekt des Deep Learning im Vergleich mit der regelbasierten klassischen Bildverarbeitung ist, dass für die Entwicklung und Programmierung von Lösungen deutlich weniger Know-how in der Bildverarbeitung notwendig ist. An die Stelle einer aufwendigen Anwendungsentwicklung rückt die Auswahl einer künstlichen neuronalen Netzstruktur basierend auf gegebenen Programmierbibliotheken, auf die dann bereits das Training und die Validierung des Algorithmus durch den zuständigen Ingenieur folgen. Dieser lehrt dem System die Logik basierend auf der Auswahl und Bereitstellung relevanter Da-

minimiert und Prüfzeiten verkürzt werden. Der Einstieg in die Implementierung von Deep-Learning-Anwendungen in der Bildverarbeitung wird durch bestehende Programmierbibliotheken wie TensorFlow erleichtert und erfordert relativ wenig Know-how in der Bildverarbeitung.

Vor dem Einsatz in der Produktion müssen die künstlichen neuronalen Netze systematisch trainiert und validiert werden. Hierfür wie auch für die anfängliche Auswahl und abschließende Überwachung des Algorithmus im Betrieb empfiehlt sich jedoch die Einbindung von Experten und professioneller Software für industrielles Deep Learning. ■