



Das Auge, das mitdenkt

Deep Learning für die industrielle Bildverarbeitung

.....
Machine-Vision-Systeme mit Deep Learning lernen eigenständig dazu und können auch vorher nicht bekannte Defekte aufspüren. So ist dank eines neuen Software-Features der MVTec Software GmbH zur Fehlererkennung nur noch eine geringe Anzahl an so genannten Gut-Bildern nötig. Das spart Trainingsaufwand und Kosten bei einer hohen Erkennungsrate.
.....

Thomas Hünerfauth

Als „Auge der Produktion“ überwacht Machine Vision die Fertigung in Echtzeit. Dabei nehmen Kameras, Scanner oder 3D-Sensoren das Geschehen aus verschiedenen Blickwinkeln auf. Die erzeugten Bilddaten werden von einer inte-

grierten Machine-Vision-Software verarbeitet und stehen für verschiedene Aufgaben entlang der Prozesskette zur Verfügung. Beispielsweise lassen sich Objekte anhand äußerer Merkmale verlässlich erkennen, lokalisieren und positionieren.

Besonders wichtig ist dies in Industrie-4.0- und Smart-Factory-Szenarien. Hier sind die Abläufe in den Produktionshallen durchgängig vernetzt und in hohem Maße digitalisiert. Machine Vision trägt dazu bei, dass alle beteiligten Akteure wie Maschinen,



Roboter, Transfer- und Handling-Systeme sowie Menschen sicher und effizient miteinander interagieren können. Auch der Einsatz kleiner, kompakter und mobiler Roboter, so genannter Collaborative Robots (Cobots), lässt sich dadurch verbessern: Diese arbeiten häufig eng mit ihren menschlichen Kollegen zusammen, teilen sich einzelne Arbeitsschritte oder reichen sich untereinander sogar Montageteile. Mittels Bildverarbeitungstechnologien lassen sich diese Prozesse genau beobachten und dadurch Kollisionen vermeiden.

Ausschuss reduzieren und Produktqualität steigern

Auch das Qualitätsmanagement profitiert in besonderer Weise von Machine Vision: Fehlerhafte Produkte werden zuverlässig identifiziert und lassen sich gezielt aussortieren, bevor sie in den weiteren Warenkreislauf gelangen. Durch die hohe Erkennungsquote kann die Ausschussrate reduziert und die Produktqualität signifikant gesteigert werden.

Machine-Vision-Systeme ermöglichen noch höhere Erkennungsraten, wenn sie mit Künstlicher Intelligenz (KI) ausgestattet sind. Dazu zählt in erster Linie Deep Learning basierend auf einer Architektur von Convolutional Neural Networks (CNNs). Diese Technologie nutzt große Mengen an digitalen Bilddaten für einen umfassenden Trainingsprozess. Dieser trägt dazu bei, dass sich mittels Machine-Vision-Software Bilddaten automatisch klassifizieren lassen. Denn im Zuge des Trainings lernt das System Besonderheiten und Merkmale, die typisch für eine bestimmte Objektklasse sind. Die präzise Zuweisung der Bilddaten zu einer spezifischen Klasse verbessert die automatische Erkennung. Auf diese Weise lassen sich mithilfe der KI-Algorithmen auch ganze Objek-

te sowie einzelne Defekte exakter lokalisieren.

Selbstlernende Systeme vs. regelbasierte Lösungen

Selbstlernende Systeme vs. regelbasierte Lösungen

Regelbasierte Lösungen verursachen einen enorm hohen Programmieraufwand, wenn sie sehr viele unterschiedliche Ausprägungen von Defekten umfassen müssen. Deep-Learning-Systeme hingegen sind dank integrierter KI in der Lage, durch das Training eigenständig dazuzulernen.

Die Fehlererkennung läuft bei regelbasierten Lösungen in einem mehrstufigen Prozess ab: Am Anfang steht das Sammeln einer ausreichend großen Menge von Trainingsbildern, die alle zu erkennenden Defekte zeigen. Im nächsten Schritt werden die Bilder gelabelt, also mit einem digitalen Etikett versehen und damit einer (Fehler-)Klasse zugewiesen, bevor sich das zugrunde liegende CNN dann auf dieser »»

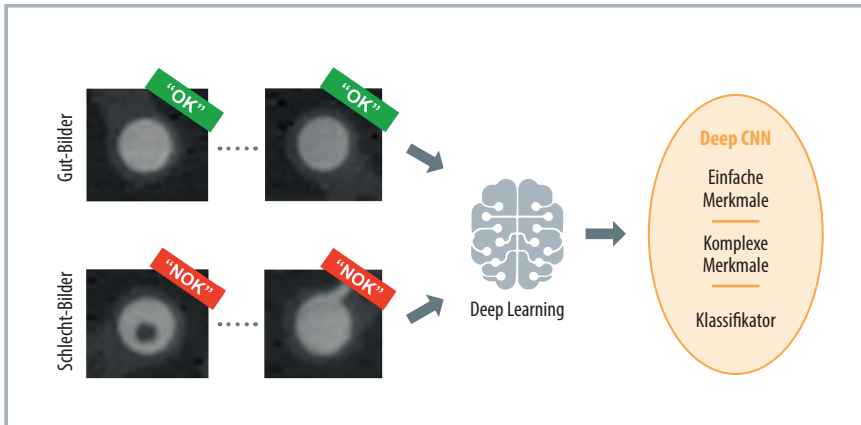


Bild 1. Deep Learning nutzt sowohl Bilder von defektfreien als auch defektbehafteten Objekten für die Fehlererkennung. Quelle: MVT, Grafik: © Hanser

Basis trainieren lässt (Bild 1). Labels können in diesem Fall z.B. „Delle“, „Kratzer“ oder „Verunreinigung“ sein. Je nach verwendeter Methode müssen auch noch relevante Bereiche im Bild markiert werden. Zwar ermöglichen Deep-Learning-Verfahren überaus robuste Erkennungsraten. Auch diese Technologie kann jedoch mit vergleichsweise hohem Aufwand verbunden sein, wenn es um Beschaffung und Labeln der Bilder geht.

Bildverarbeitungssoftware mit integriertem Deep Learning

Seit mehreren Jahren bietet das Münchner Unternehmen MVTec Software GmbH in seiner Machine-Vision-Standardsoftware Halcon vortrainierte Deep-Learning-Netze. Das bedeutet, dass Anwender die Netze für ihre Anwendung nur noch nachtrainieren müssen, um sie an die jeweilige Aufgabe anzupassen.

Obwohl das Nachtrainieren eines Netzes grundsätzlich wesentlich weniger Bilder erfordert als das komplette „Neu-“trainieren, wird auch hier noch eine relativ große Anzahl von Trainingsbildern benötigt. Diese müssen allesamt gelabelt werden, um sie einer bestimmten Klasse zuzuweisen. Für einen erfolgreichen Trainingsprozess sind zudem normalerweise so genannte Schlecht-Bilder erforderlich. Das Besondere daran ist, dass sie die Objekte mit den jeweils zu erkennenden Defekten im Motiv zeigen. Soll beispielsweise ein spezielles Elektronikteil auf Fehler geprüft werden, müssen hiervon, je nach Komplexität der Aufgabe, zwischen 50 und 300 Bilder pro Defekttyp aufgenommen werden. Auf diesen muss das entsprechende Objekt mit

verschiedensten Erscheinungsformen von Defekten wie Kratzer, Verformungen, Risse oder Dellen zu sehen sein. Dieses Sammeln und Labeln der Bilder kann viel Zeit kosten. Zudem sind Anwendungen denkbar, bei denen Schlecht-Bilder nicht in so großer Anzahl bereitgestellt werden können.

Weniger Trainingsbilder nötig durch Verwendung von Gut-Bildern

Seit der Halcon-Version 19.11 gibt es das Feature Anomaly Detection, das in der aktuellen Version stark weiterentwickelt wurde. Dieses Tool erfordert für das Training des Deep-Learning-Netzes nur noch etwa 20 bis maximal 100 Beispielbilder. Zudem werden keine Schlecht-Bilder benötigt. Für den Trainingsvorgang reichen nun Bilder aus, die das jeweilige Objekt ohne Defekt, also in einwandfreiem Zustand zeigen (sog. Gut-Bilder). Das System kann nach dem Training selbstständig in allen weiteren Bildern gleicher Objekte Anomalien, also Fehler, unterschiedlichster Ausprägungen erkennen und lokalisieren. Dadurch entfällt der aufwendige Labeling-Prozess von Schlecht-Bildern.

Das neue Feature ist in der Lage, auch Defekte mit bisher unbekanntem Erscheinungsbild zu entdecken. Solche Abweichungen können etwa in der Farbe, der Struktur oder auch in einer Kontamination bestehen. Ein Beispiel: Ein Getränkehersteller muss die Gefäße vor der Befüllung genauestens prüfen. Die Anomaly-Detection-Technologie kann dabei verschiedenste – vorher nicht bekannte – Defekte wie kleinste Kratzer, Risse oder Sprünge am Flaschenhals exakt aufspüren und lokalisieren.

Nachdem das Netz mit den Gut-Bildern trainiert wurde, liefert die Inferenz – das Ausführen des Prüfschrittes – eine so genannte Anomaly Map. Auf dieser werden mithilfe eines Grauwerts bestimmte Regionen gekennzeichnet, die mit hoher Wahrscheinlichkeit eine Anomalie aufweisen. Durch die Segmentierung dieser Anomaly Map kann das System pixelgenau Fehler lokalisieren und präzise deren Größe ermitteln. Die Zeit für das Training mit 20 Bildern liegt hier seit der Version 20.05 von MVTec Halcon bei nur etwa sechs Minuten. Mit Anomaly Detection lassen sich also schon nach kurzer Zeit, mit wenigen Daten und ohne Label-Aufwand erste Ergebnisse erzielen. ■

INFORMATION & SERVICE

AUTOR

Thomas Hünerfauth ist Product Owner Halcon Library bei der MVTec Software GmbH, München.

KONTAKT

MVTec Software GmbH
T 089 4576950
info@mvtec.com
www.mvtec.com