



# Fehlerraten reduzieren mit Computer Vision

**KI-gestützte Software für die Fehlerinspektion**

Skalierbare Computer-Vision-Modelle erleichtern die Fehlererkennung, Montageüberprüfung oder Konformität von Produktionsanwendungen. Das junge Unternehmen 36Zero Vision liefert eine neue Technologie, die menschenähnliche Fehlererkennung mit Robustheit gegenüber Umweltveränderungen kombiniert.

Florian Ziesche, Zeeshan Karamat, Felipe Barreto

object  
94X34  
inspec  
L3FG  
results

**B**ildverarbeitungsanwendungen für die Sichtprüfung in der Industrie haben den Herstellern starke Werkzeuge an die Hand gegeben, mit denen sie ihre Produktivität erheblich steigern können. Der größte Anteil an Automatisierung durch Fehler- und Anomalieerkennung besteht jedoch aus hochvolumigen, sich wiederholenden und oft unveränderlichen Produktionsprozessen. Andere visuelle Inspektionsaufgaben werden weiterhin aus triftigen Gründen manuell durchgeführt. Die verfügbaren Technologien sind noch nicht allen Anforderungen einer globalisierten Industrielandschaft gewachsen.

Bisher konnte nur der Mensch die ständig steigenden Qualitätsanforderungen bewältigen. Doch menschliche Arbeitskräfte werden von Jahr zu Jahr knapper, und das Fachwissen, die Geschicklichkeit und der Einsatz talentierter Qualitätsarbeiter sind weder skalierbar noch leicht übertragbar. Compu-

ter-Vision-Lösungen, die durch künstliche Intelligenz ergänzt werden, verleihen Maschinen eine menschenähnliche Fähigkeit, die negativen Auswirkungen unvorhergesehener oder schwieriger Umgebungsbedingungen in der Fertigung, wie wechselnde Beleuchtung, Positionsänderungen oder sich bewegende Objekte und Produktkomplexität, erheblich zu reduzieren. Dennoch ist diese Technologie für die meisten Hersteller noch schwierig, da sie mit teuren Ressourcen verbunden ist.

### Produktionsreife Computer-Vision-Modelle


Bekanntere Probleme aus der industriellen Bildverarbeitung inspirierten 2007 den Wettbewerb „Weakly Supervised Learning for Industrial Optical Inspection“, der im Rahmen des Symposiums der IAPR (International Association for Pattern Recognition) und des deutschen Verbands der European >>>

ID:  
BS  
tionID:  
:NOK

Neural Network Society veranstaltet wurde. Technologieanbieter müssen für diesen Wettbewerb einen eigenständigen Algorithmus oder ein neuronales Netz zur Erkennung verschiedener Defekte und Anomalien entwickeln. Die besondere Herausforderung bestand darin, dass das neuronale Netz ohne menschliches Eingreifen lernen muss, Defekte automatisch aus einem schwach markierten Datensatz zu erkennen, das heißt aus Markierungen lernen muss, die nicht genau auf Pixelebene sind. Die genauen Defektmerkmale sind dem neuronalen Netz zum Zeitpunkt der Entwicklung unbekannt.

Die bereitgestellten Daten für den Wettbewerb wurden künstlich erzeugt und sollten den realen industriellen Problemen möglichst nahekommen. Der Benchmark-Datensatz DAGM 2007 bestand aus Datensätzen, die ursprünglich für die Entwicklung des neuronalen Netzes berücksichtigt wurden, und Datensätzen, die für den Wettbewerb verwendet wurden. Jeder Datensatz bestand aus 1000 Bildern mit verschiedenen Hintergrundtexturen ohne Fehler und 150 Bildern mit einem beschrifteten Fehler pro Bild. Dabei war das Texturmuster innerhalb eines einzelnen Datensatzes homogen, das heißt zwischen den unterschiedlichen Datensätzen waren die Daten heterogen mit unterschiedlichen Texturmustern und Defekteigenschaften. Darüber hinaus waren nicht alle Texturabweichungen notwendigerweise Defekte.

Das Bild oben zeigt zwei Beispiele aus zwei Datensätzen. Für beide Klassen zeigt das linke Bild keinen Fehler; das rechte Bild enthält einen Fehler in Form einer dünnen dunklen Linie und eines diffusen dunkleren Bereichs. Die roten Ellipsen beschreiben die für dieses Auswahlverfahren charakteristischen schwachen Markierungen.



Zwei Beispiele aus zwei Datensätzen: Für beide Datensätze wird das linke Bild nicht angezeigt; das rechte enthält einen Defekt, der als diffuser dunklerer Bereich erscheint. Die roten Ellipsen beschreiben die für diesen Wettbewerb charakteristischen schwachen Markierungen. © Matthias Wieler, Tobias Hahn, Fred. A. Hamprecht (2007)

### Der Wettbewerb

Die Technologieanbieter verwendeten sechs von zehn Datensätzen für die Algorithmenentwicklung im Wettbewerb, die als Entwicklungsdatensätze bezeichnet werden. Die Teilnehmer nutzten die verbleibenden vier Datensätze, die als Wettbewerbsdatensätze bezeichnet werden, zur Bewertung der Modellleistung. Als Ehrenkodex sollten die Teilnehmer die Wettbewerbsdatensätze nicht vor der Entwicklung des neuronalen Netzes verwenden oder analysieren. Bei der Leistungsbewertung sollten die Teilnehmer asymmetrische Kosten für falsch-positive und falsch-negative Entscheidungen berücksichtigen (für den Wettbewerb wurde ein Verhältnis von 1:20 verwendet).

### Edge-Technologien im Test

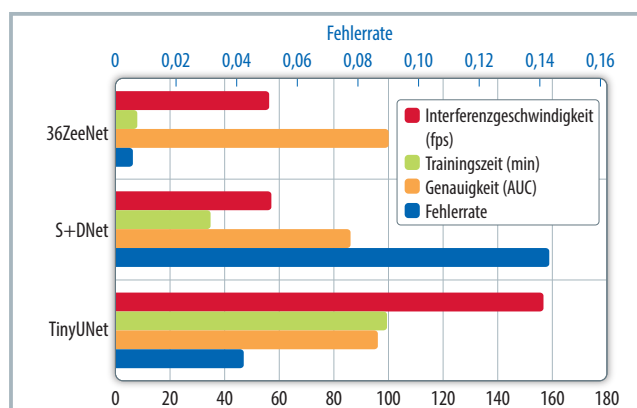
Im Gegensatz zur Ausgangssituation im Jahr 2007 haben die Innovationen der vergangenen Jahre zu erheblichen Verbesserungen bei der Leistung neuronaler Netze geführt, sodass eine Genauigkeit erreicht wurde, die damals noch nicht umsetzbar war. Der Wettbewerbsrahmen bleibt jedoch ein wichtiger Maßstab für die Erprobung von Spitzentechnologien, die von führenden Technologieanbietern und Forschungseinrichtungen entwickelt werden.

Der Technologieanbieter 36Zero Vision, Nvidia und die Forscher der Fakultät für Computer- und Informationswissenschaften an der Universität Ljubljana verwendeten neuronale Netze, die nicht, wie auf dem ursprünglichen Symposium angegeben, mit den ursprünglichen sechs Datensätzen entwickelt wurden. Stattdessen führten sie den Benchmark mit eigenen, angepassten und selbst entwickelten Netzen durch. Die bewerteten Modelle wurden mit den im DAGM 2007 zur Verfügung gestellten Trainingsdatensätzen trainiert, ohne manuelle Manipulationen an den Bildern und Annotationen.

Die entwickelten Modelle wurden nach ihrer Genauigkeit anhand der Area-under-the-Curve-Methode (AUC) bewertet, die Aufschluss darüber gibt, wie gut ein Modell einen Defekt unter Berücksichtigung der Richtig-Positiv- und Falsch-Positiv-Raten klassifiziert. Größere AUC-Werte beschreiben eine bessere Diskriminierung des Modells. Der TinyUNet von Nvidia ist eine Adaption des ursprünglichen UNet-Modells, einem Faltungs-Autoencoder für die

Vergleichende Zusammenstellung neuronaler Netze. Quelle: 36Zero

Vision © Hanser



### Modelle und Netzwerke

Der TinyUNet von Nvidia ist eine Adaption des ursprünglichen UNet-Modells, einem Faltungs-Autoencoder für die

Die entwickelten Modelle wurden nach ihrer Genauigkeit anhand der Area-under-the-Curve-Methode (AUC) bewertet, die Aufschluss darüber gibt, wie gut ein Modell einen Defekt unter Berücksichtigung der Richtig-Positiv- und Falsch-Positiv-Raten klassifiziert. Größere AUC-Werte beschreiben eine bessere Diskriminierung des Modells.

2D-Bildsegmentierung. Im Gegensatz dazu entwickelten die Forscher der Universität Ljubljana ein neuronales Netzwerk mit einer Architektur, die auf zwei Subnetzen basiert, wobei sich die erste Unterkomponente auf das Lernen basierend auf Pixel-Level-Labels konzentrierte und die zweite sich auf die Klassifizierung schwacher Bild-Level-Labels konzentrierte, die in diesem Artikel als Segmentierung + Decision Net (S+DNet) bezeichnet werden.

Die zum Patent angemeldete Technologie 36ZeeNet vom jungen Unternehmen 36Zero Vision ist ein proprietäres, pixelbasiertes und panoptisches Netzwerk, das durch umfangreiche Forschung und unter Verwendung hochqualitativer Datenpunkte aus verschiedenen realen industriellen Szenarien entwickelt wurde.

Unter Berücksichtigung der Verwendung ähnlicher Systemarchitekturen für das Training des Modells, nämlich Nvidia DGX-1 (8x V100 16GB) im Falle von 36ZeeNet und TinyUNet-Industrial und RTX 2080Ti für S+DNet, erreichte das aus dem 36ZeeNet resultierende Modell mit einem Wert von 0,99886 die höchste Genauigkeit. Diesen Wert kann man als Durchbruch bezeichnen, mit einer Fehlerrate, die 29-mal kleiner ist als die des Konkurrenznetzwerks TinyUNet-Industrial und 114-mal kleiner als die des Netzwerks S+DNet.

### Vorlaufzeit und Skalierbarkeit

Bei der Qualitätskontrolle ist nicht nur die Genauigkeit, sondern auch die Vorlaufzeit und die Skalierbarkeit einer Lösung für die Fehlerprüfung von entscheidender Bedeutung. 36Zero Vision lieferte ein skalierbares und verallgemeinerbares Modell, das für jeden Datensatz verwendet werden konnte, im Gegensatz zu einem Modell für jede einzelne Datensatz-Klasse.

### Praxisrelevante Vorteile

Die Technologie von 36Zero Vision wurde durch umfangreiche Forschung mit Daten aus realen Industrieumgebungen mit über 22 Millionen Datenpunkten aus verschiedenen Produktionsumgebungen entwickelt. Diese Bemühungen lieferten eine Plattform, die es ermöglicht, anpassbare, skalierbare und verallgemeinerbare Computer-Vision-Modelle zu generieren.

Das Netzwerk ermöglicht Datensimulationen mit über 50 verschiedenen Para-



Lösungsmodule: Fehlererkennung, Optical Character Recognition und Konformität der Produktion

© 36ZeroVision

metern wie nichtlineare Verformungen, Cut-Paste-Polygone, fotorealistische Transformationen, um komplexe industrielle Umgebungen zu antizipieren und ein Vielfaches an Daten aus einem kleinen Ausgangsdatsatz zu generieren. Dies ermöglicht eine Modellleistung, die eine menschenähnliche Fähigkeit zur Erkennung von Defekten bietet, robust gegenüber Veränderungen der Beleuchtung, der Objektorientierung und -position ist. Dennoch bietet die Lösung eine schnellere Bereitstellung aufgrund geringerer Hardwareanforderungen, da die Computer-Vision-Modelle auf verfügbarer Hardware und auf nicht-industriellen Endgeräten wie einem Smartphone eingesetzt werden können.

Im Gegensatz zu anderen State-of-the-Art-Modellen, die normalerweise mit Auflösungen von 256x256 oder 512x512 Pixeln arbeiten, gibt es bei der 36Zero-Vision-Technologie auch bei typischen hohen Bildauflösungen kein Overfitting. Durch die Implementierung von mehr als 50 Parametern wird eine Überanpassung verhindert. Auf diese Weise können komplexere Objekte mit höher aufgelösten Bildern analysiert werden, was die Inspektion von kleineren und unkonventionellen Objekten ermöglicht, die in jeder Produktionsumgebung vorkommen.

Die Modellerstellung und -einrichtung kann innerhalb eines Tages durchgeführt werden und erfordert keine umfangreichen Forschungs- oder Codierungskennnisse.

Der Benutzer muss einen kleinen repräsentativen Datensatz auf die 36Zero-Vision-Plattform hochladen. Die Modelle können dann entwickelt werden, indem bis zu 30 verschiedene ROI (Region of Interest) pro Bild und bis zu 30 verschiedene Qualitätsmerkmale pro ROI definiert werden. Das Computer-Vision-Modell kann im Anschluss auf jeder verfügbaren Hardware vor Ort eingesetzt werden und ist sofort einsatzbereit. ■

## INFORMATION & SERVICE

### AUTOREN

Zeeshan Karamat ist CTO und Mitgründer, Florian Ziesche CEO und ebenfalls Mitgründer von 36Zero Vision. Felipe Barreto ist Head of Operations beim Unternehmen 36Zero Vision.

### UNTERNEHMEN

Das Start-Up 36Zero Vision bietet eine KI-gestützte Lösung für die visuelle Qualitätssicherung in der Fertigung. Das Know-how basiert auf proprietären Deep-Learning-Algorithmen, um intelligente Computer-Vision-Modelle zu entwickeln.

### KONTAKT

36ZERO Vision  
T +49 151 230 39-208  
www.36zerovision.com  
info@36zerovision.com