



# Oberflächenschäden automatisch detektieren

## Automatisierte und KI-basierte Erkennung von Fahrzeugschäden

Um den Wert eines Fahrzeugs zu beurteilen, spielen vor allem Fahrzeugschäden eine entscheidende Rolle. Für viele Geschäftsmodelle in der Mobilität sind daher aktuelle Informationen über den Zustand eines Fahrzeuges wichtig. Eine automatisierte Inspektionslösung, die Karoserieschäden objektiv erfasst, analysiert und dokumentiert, ist hilfreich.

Frederik Seiler und Ira Effenberger

Insbesondere Fahrzeugvermietungen und Leasingfirmen prüfen den Zustand der Rückläufer und gleichen die vorhandenen Schäden mit bereits bekannten Beschädigungen ab, um ein aktuelles Bild des Fahrzeuges zu erhalten und notwendige Reparaturen durchführen zu lassen.

Weiterhin sind Werkstätten, Gutachterorganisationen oder Versicherungen an der Erfassung und Dokumentation von Schäden interessiert. Die Bestimmung der

am Fahrzeug auftretenden Schäden ist bisher jedoch ein weitestgehend manueller Prozess, bei dem die Schäden von einem Mitarbeiter durch visuelle Inspektion des Fahrzeuges ermittelt und notiert werden.

Diese Sichtprüfung der Fahrzeuge lässt sich durch eine KI-basierte Bildauswertung automatisieren. In hochaufgelösten Farbbildern vom zu untersuchenden Fahrzeug können mit Hilfe von KI-basierten Verfahren Oberflächenschäden an der Karosserie

automatisch detektiert werden. Dadurch entfällt die manuelle und somit subjektive Prüfung der Fahrzeuge.

Die Fahrzeugschäden werden mit Hilfe von Farbkameras, intelligenter Beleuchtung und KI-basierter Schadensdetektion automatisch erfasst und am Fahrzeug visualisiert, wodurch sich die Inspektionszeit der Rückläufer verkürzen und die Schadensanalyse objektivieren lässt.

»»



Bild 1. Die Fahrzeuge werden in einer Scanstation von mehreren Kameras erfasst.

© Fraunhofer IPA

### Datenerfassung erfolgt in einer Scanstation

Die Datenerfassung erfolgt in einer Scanstation, die sowohl im Indoor- als auch im Outdoor-Bereich einsetzbar ist. Während das Fahrzeug durch die Scanstation fährt, wird es aus unterschiedlichen Perspektiven von mehreren Kameras erfasst. Die Kameras, die auf beweglichen Säulen angeordnet sind, drehen sich mit dem Fahrzeug mit, sodass das Fahrzeug zunächst von vorne, anschließend von beiden Seiten und beim Verlassen der Scanstation von hinten aufgenommen wird (Bild 1).

Somit entsteht eine Sammlung von hochauflösenden Farbbildern, in denen die Karosserie des Fahrzeuges erfasst ist. Die einzelnen Bilder können dabei einen Überlappungsbereich aufweisen, um eine zusätzliche Redundanz zu erzeugen. Die Datenerfassung ist durch die on-the-fly Bildaufnahme in wenigen Sekunden abgeschlossen. Auf den Bildern der zu prüfenden Fahrzeuge müssen unterschiedliche Typen von Fahrzeugschäden detektiert werden. Dazu gehören u.a. Felgenschäden, Kratzer, Dellen und Verformungen. Die automatische Erkennung der Fahrzeugschä-

den ist eine anspruchsvolle Aufgabe. Zu den Herausforderungen zählen die Aufnahmebedingungen, die große Anzahl an Fahrzeugen und die hohe Varianz der auftretenden Schäden. Auf diese drei Aspekte wird im Folgenden näher eingegangen:

Die Scanstation kann in unterschiedlichen Umgebungen aufgebaut werden. Dadurch verändert sich das Umfeld, in dem die Fahrzeuge aufgenommen werden. Die auftretenden Reflexionen sind von der Aufnahmeumgebung abhängig und unterscheiden sich bei Indoor- und Outdooranlagen stark. Bei Scanstationen im Außenbereich werden die Kameraaufnahmen durch das Wetter und die Jahreszeit beeinflusst. Somit sind die Lichtverhältnisse bei der Bildaufnahme sehr unterschiedlich und wirken sich entsprechend auf die Bildqualität aus. Weiterhin können sich in der Umgebung des Fahrzeugscanners befindliche Gebäude, Schilder oder Bäume auf dem Fahrzeug spiegeln und dadurch die Schadenserkenner erschweren.

Eine weitere Herausforderung besteht in der großen Bandbreite an zu untersuchenden Fahrzeugen. Die Fahrzeuge variieren in Größe, Farbe und Modell. Für die Schadenserkenner steht kein a priori Wissen über die Fahrzeuge zur Verfügung und es werden keine Modelle der Fahrzeuge genutzt. Außerdem kann nicht vorausgesetzt werden, dass die Fahrzeuge in gewaschenem Zustand durch den Scanner fahren. Sie




Bild 2. Vor der Schadenserkenner wird das Fahrzeug in die einzelnen Fahrzeugteile segmentiert. © Fraunhofer IPA



**Bild 3.** Dellen erzeugen eine charakteristische Verzerrung der Streifenbeleuchtung und können somit indirekt detektiert werden. © Fraunhofer IPA



**Bild 4.** Am Fahrzeug werden von der automatischen Schadenserkennung ein Felgenschaden (blau), eine Verformung (gelb) und Kratzer (grün) erkannt. Im Bereich der Stoßstange sind auch Verschmutzungen zu erkennen, die richtigerweise nicht als Fehlstellen erkannt werden. © Fraunhofer IPA

können verschmutzt oder nass vom Regen sein. Somit ergibt sich insgesamt ein sehr großes Spektrum an Fahrzeugen und Fahrzeugzuständen für die Schadensdetektion.

Die große Vielfalt an unterschiedlichen Schadensbildern stellt eine weitere Herausforderung dar. Die Fahrzeugschäden treten in unterschiedlicher Ausprägungsform und Größe auf. Daher ist es nicht möglich nach einem spezifischen Schadensmuster zu prüfen, sondern es müssen die schadensspezifischen Merkmale identifiziert werden. Aus diesem Grund bietet sich ein Ansatz an, der auf künstlicher Intelligenz (KI) basiert.

### Verwendung tiefer Neuronaler Netze (Deep Learning Verfahren)

Um in den Kamerabildern von Fahrzeugen Schäden zu identifizieren, werden tiefe Neuronale Netze (Deep Learning Verfahren) verwendet. Während einer Trainingsphase wird zunächst gelernt, welche Merkmale für die Fahrzeugschäden charakteristisch sind und welche Merkmale bei einem Fahrzeug typischerweise vorkommen. Die Grundlage für den Lernprozess bildet ein Trainingsdatensatz. Dieser besteht aus repräsentativen Bildern von unterschiedlichen Fahrzeugen mit manuell annotierten Fahrzeugschäden. Hierbei ist zu beachten, dass der Annotationsprozess subjektiv ist. So können beispielsweise mehrere nebeneinander liegende Defekte einzeln oder als ein großer Defekt von der annotierenden Person gekennzeichnet werden. Es entste-

hen Mehrdeutigkeiten, die das Training negativ beeinflussen können. Ein weiterer Interpretationsspielraum entsteht bei der Unterscheidung der Fehlerklassen. Die einzelnen Schadensbilder lassen sich häufig nicht eindeutig einer Schadenskategorie zuordnen. Verformungen enthalten z.B. oft auch die Merkmale von Kratzern und lassen sich außerdem nicht immer klar von Dellen abgrenzen.

Der genutzte Datensatz besteht aus insgesamt 10000 Bildern, die jeweils mindestens einen Schaden enthalten. Die häufigste Schadensklasse sind Felgenschäden mit einem Anteil von 55%, gefolgt von Kratzern (28%) und Dellen (6%). Die Auflösung der Bilder beträgt 4096 x 3000 Pixel.

### Ende-zu-Ende-Lernprozess defektspezifischer Merkmale

Für das Training wird die Schadenserkennung als ein Objektdetektionsproblem interpretiert und ein neuronales Netz zum Erlernen der defektspezifischen Merkmale genutzt und in einem Ende-zu-Ende-Lernprozess trainiert. Das Netz besteht aus einem Feature Extraction Network, einem Feature Pyramid Network, einem Region Proposal Network und Netzwerken für die Objektklasse, die Boxen und die pixelgenaue Segmentierung. Mit dem Feature Extraction Network werden aus dem originalen Bild Merkmale gewonnen, auf deren Basis die Schäden erkannt werden. Mit zunehmender Tiefe des Netzwerkes steigt der Abstraktionsgrad der erlernten Merkmale.

Anschließend werden die resultierenden Merkmalskarten mit unterschiedlichen Abstraktionsgrad miteinander fusioniert. Für Detektion und Klassifikation der Schäden werden Merkmalskarten mit unterschiedlichem Abstraktionsgrad genutzt, um Fahrzeugschäden unterschiedlicher Größe möglichst robust detektieren zu können. Die Hyperparameter des Netzwerkes und die genaue Definition der Kostenfunktion, die während des Trainings minimiert wird, werden für die Aufgabenstellung der Schadenserkennung an Fahrzeugen optimiert.

### Weiteres Netzwerk für die Erkennung der Fahrzeugteile

Zusätzlich zur Schadenserkennung wird ein weiteres Netzwerk für die Erkennung der Fahrzeugteile genutzt. Dabei werden u.a. Stoßfänger, Reifen, Felgen, Türen, Scheiben oder die Motorhaube des Fahrzeugs segmentiert (Bild 2).

Weiterhin wird das Fahrzeug vom Hintergrund segmentiert. Diese Segmentierung wird genutzt, um den Hintergrund vor der Schadenserkennung zu entfernen. Dadurch verringert sich die Rechenzeit und Fehldetektionen im Hintergrund können verhindert werden. In den vorverarbeiteten Bildern werden dann mit dem Schadenserkennungsnetzwerk die einzelnen Schäden erkannt und pixelgenau segmentiert. Die erkannten Fehlstellen lassen sich mit Hilfe der Fahrzeugteilessegmentierung am Fahrzeug lokalisieren und den entspre- >>>

chenden Fahrzeugbereichen zuordnen.

Für die Optimierung der Detektionsergebnisse wurden unterschiedliche Einflussfaktoren getestet. Eine große Verbesserung kann dabei durch Modifikationen der Bilder während des Trainings erzielt werden. Hierfür werden während des Trainings zufällige Ausschnitte der Bilder des Trainingsdatensatzes genutzt. Dadurch werden die Schadensbilder in unterschiedlichen Größen gelernt und die Schadensdetektion wird robuster. Eine weitere signifikante Verbesserung ergibt sich durch Spiegelung der Bilder entlang der Horizontalen,

Vertikalen und Diagonalen, da sich dadurch der Trainingsdatensatz vergrößert. Ein weiterer Einflussfaktor ist die Ausgangsgröße der Bilder. Bei einer Verringerung der Auflösung der Bilder steigt die Geschwindigkeit der Schadenserkenkung, jedoch sinkt die Erkennungsrate bei kleinen Schäden. Eine Unterteilung des Bildes in kleinere Kacheln mit einer anschließenden Fusion der detektierten Schäden führt zu keiner Verbesserung, da durch die Reduktion des Bildausschnittes wichtige Kontextinformation verloren geht und vermehrt fehlerhafte Detektionen auftreten. Daher werden die Bilder vor der Schadenserkenkung nicht in Kacheln unterteilt, sondern die originalen Bilder auf 2048 x 1500 Pixel skaliert.

Dellen können in den Kamerabildern schwer erkennbar oder unsichtbar sein. Durch eine strukturierte Beleuchtung lässt sich die Erkennung von Dellen deutlich verbessern. Dazu wird in der Scanstation eine Leuchte angebracht, die Streifen auf die Fahrzeuge projiziert (Bild 3). Dellen und Verformungen erzeugen eine charakteristische Verzerrung dieser Streifen. Im Laufe des Trainingsprozesses werden die durch Dellen entstehenden Muster erlernt. Somit findet durch das projizierte Streifenmuster eine indirekte Detektion der Dellen statt. Bei der näheren Untersuchung der nicht gefundenen Schäden lässt sich erkennen, dass wichtiger als die Stärke der Schäden ihre Repräsentation im Datensatz ist. Je Häufiger eine Defektklasse im Trainingsdatensatz vorhanden ist, desto zuverlässiger ist die Detektion. Bei Schäden mit einem untypischen Erscheinungsbild kann die Repräsentation in den Trainingsdaten unzureichend sein und damit zu einer weniger robusten Detektion führen. Somit ist nicht die Schwere eines Schadens, sondern die Anzahl an vergleichbaren Schadensbildern im Datensatz ausschlaggebend für die korrekte Erkennung eines Schadens.

### Testdatensatz aus 739 Bildern mit über 1000 annotierten Schäden

Für den Test der Erkennung der Fahrzeugschäden wurde ein repräsentativer Testdatensatz genutzt. Dieser Testdatensatz besteht aus 385 Bildern mit über 1000 annotierten Schäden, die nicht im Trainingsdatensatz vorhanden waren, sowie 354 Bildern von Fahrzeugen, die keine Schäden

aufweisen. Durch das Hinzufügen der Bilder von Fahrzeugen ohne Defekte wird ein Fokus auf die Falschpositivrate gelegt. Durch fehlerhafte Detektionen werden manuelle Korrekturen notwendig und somit sinkt die Akzeptanz eines Systems zur automatischen Schadenserkenkung. Die Erkennungsraten auf dem Testdatensatz liegen für die Klasse Delle bei 61%, die Klasse Felgenschäden bei 83% und die Klasse Kratzer bei 68 %. Die Genauigkeit der Detektionen beträgt bei der Schadenskategorie Delle 70 %, bei Felgenschäden 76 % und bei Kratzern 61 %. Bei den Fehldetektionen kann es sich um Falschpositive handeln, die beispielsweise durch Schmutz am Fahrzeug entstehen können. Hierbei ist es häufig auch für den Menschen im Kamerabild nicht mit Sicherheit feststellbar, ob es sich um einen Schaden oder um eine Verschmutzung handelt. Diese Mehrdeutigkeiten unterliegen einer Subjektivität in der Bewertung und sind eine häufige Ursache von Fehldetektionen. Ein weiterer Grund für fehlerhafte Detektionen kann in falsch zugeordneten Schadenskategorien liegen. Da die Schadensbilder häufig Merkmale von mehreren Schadenskategorien aufweisen, kann ein Defekt einer falschen Kategorie zugewiesen werden. Dadurch entsteht in der Statistik sowohl eine Falschdetektion, als auch ein nicht erkannter Schaden.

Somit lässt sich mit einer KI-basierten Schadenserkenkung ein Großteil der Fahrzeugschäden automatisch identifizieren und pixelgenau segmentieren (Bild 4). Während des Trainingsvorgangs werden sowohl die charakteristischen Merkmale der Schäden gelernt, als auch welche Formen und Strukturen bei Fahrzeugen üblich sind und somit kein Fehlerbild darstellen. Die KI-Entwicklung wurde im Rahmen des KI-Fortschrittszentrums, das vom Land Baden-Württemberg gefördert wird, in Kooperation mit den Firmen TwoTronic und Gal&Tas durchgeführt, die Bilddaten aus dem Fahrzeugscanner und die annotierten Fehlerbilder zur Verfügung gestellt haben.

Die entwickelte KI-basierte Schadenserkenkung lässt sich neben der Bewertung des Zustands von Fahrzeugen im Gebrauch auch auf andere Anwendungen im Produktionsumfeld übertragen und kann beispielsweise zur Automatisierung der Oberflächenprüfung oder Rissprüfung in der Fertigung eingesetzt werden. ■

## INFORMATION & SERVICE

### AUTOREN

**M. Sc. Frederik Seiler** ist wissenschaftlicher Mitarbeiter am Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA und forscht an KI-Verfahren auf Basis optischer Sensordaten, die sowohl bei der Detektion von Fehlstellen als auch bei der Objekterkennung Anwendung finden.

**Dr.-Ing. Ira Effenberger** ist Gruppenleiterin am Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA in Stuttgart und arbeitet mit Ihrer Gruppe an der intelligenten Auswertung von Bild- und Sensordaten für die Qualitätssicherung und die Automatisierung.

### INSTITUT

Das Fraunhofer IPA – eines der größten Institute der Fraunhofer-Gesellschaft – wurde 1959 gegründet und beschäftigt annähernd 1200 Mitarbeiterinnen und Mitarbeiter. Organisatorische und technologische Aufgabenstellungen aus der Produktion machen die Forschungs- und Entwicklungsschwerpunkte aus. Die 19 Fachabteilungen des Fraunhofer IPA decken den gesamten Bereich der Produktionstechnik ab.

### KONTAKT

Frederik Seiler  
frederik.seiler@ipa.fraunhofer.de