

# Automatisierte Inspektion von stahlbaulichen Strukturen mittels Drohne im Innenbereich

## Automated Drone-based Inspection of Steel Structures in Indoor Areas

Tina Ambrosat | Fabian Gierschner | Annika Hundrup | Thomas Harweg |  
Frank Weichert | Dieter UngermaNN | Wilko Flügge

### Zusammenfassung

Bauwerke sind Langfristobjekte, die im Verlauf ihrer planmäßigen Nutzung einer Degradation unterliegen. Eine zeitnahe Instandsetzung von Mängeln und Schäden ermöglichen den Erhalt und die Funktion der Bauwerke über ihre gesamte Nutzungsdauer. Zur Erkennung dieser Mängel und Schäden werden regelmäßige Bauwerksprüfungen durchgeführt, die sehr zeit- und personalintensiv sowie mit Beschränkungen der Bauwerksnutzung während der Bauwerksprüfung verbunden sind. Zur Reduzierung dieser Beschränkungen wird in diesem Artikel eine automatisierte Zustandserfassung durch Befliegung von Bauwerken mit unbemannten Flugobjekten, einer anschließenden automatisierten Bildauswertung mit Schaden- sowie Mängelerkennung und einer Bauzustandsbewertung vorgestellt. Mit dem vorgestellten System können Bauwerksprüfungen schnell, kostengünstig und objektiv durchgeführt werden.

**Schlüsselwörter:** Bauwerksinspektion, Schadenerkennung, UAV, Indoor-Positionsbestimmung, KI-gestützte Bilderkennung

### Summary

*Constructions are of long-term nature and degrade during their lifetime. A prompt restoration of defects can ensure the building's function and preservation. Usually, there are personnel-intensive and time-consuming periodic building examinations to*

*find these defects and harms. Moreover, the construction's use is mostly limited during these inspections. To avoid these regular use limitations, this article presents an automatic detection of the building's status by means of Unmanned Aerial Systems, an automatic image analysis with damage detection, and finally an assessment of the building's condition. With the presented system, the building inspections could be carried out objectively and in a time- and cost-effective manner.*

**Keywords:** building inspection, damage detection, UAV, indoor localization, AI-based image recognition

### 1 Einleitung

Ingenieur- und Hochbauten sind technische Bauwerke, die extremen statischen und dynamischen Beanspruchungen unterliegen. Feuchtigkeit, Kalt-Warm-Wechsel, Schnee-, Verkehrslasten oder auch Verschleiß, welche eine Baustruktur z. T. bis aufs Äußerste beanspruchen, können zu einer Schädigung, Nutzungseinschränkung oder im Extremfall zu einem Einsturz führen. Problematisch ist dabei, dass Schädigungen wie Risse oder Korrosion nahezu immer sehr klein und kaum von Weitem zu erkennen sind (vgl. Abb. 1). Lange unentdeckt führen jedoch genau solche



Abb. 1: Beispielhafte zu inspizierende Stahlhalle<sup>1</sup> (links) und mögliche Schäden an Stahlkonstruktionen<sup>2</sup> (Mitte) mit Detailansichten (rechts)

<sup>1</sup> <https://image.jimcdn.com/app/cms/image/transf/none/path/s91988456937ebc76/image/ibb19ddb28c66bfea/version/1464807655/moderner-hallenbau-stahlhalle-mit-cosmolite.jpg>, letzter Zugriff 27.01.2023

<sup>2</sup> Bilder mit Genehmigung von PSP – Prof. Sedlacek & Partner, Planung und Entwicklung im Bauwesen, Büro Dortmund

Schädigungen zu gravierenden Folgen für die Tragwirkung und somit für die Sicherheit, Nutzbarkeit und Wirtschaftlichkeit des Bauwerks.

Da diese Bauten oft Bestandteil der Infrastruktur oder großer Produktionsstätten sind, z.B. Industrieanlagen, Freizeitbauwerke oder Brücken, ist der Erhalt der Stand- und Verkehrssicherheit über einen größtmöglichen Zeitraum zwingend erforderlich. Deswegen ist die regelmäßige (Sicht-)Prüfung von baulichen Anlagen durch ausgebildetes und erfahrenes Personal essenziell und bei Konstruktionen im Zuge von Straßen wie Brücken oder Lärmschutzwänden sogar vorgeschrieben (Bauministerkonferenz 2006, Deutsches Institut für Normung e.V. 1999a). Zur Durchführung einer solchen Sichtprüfung wird die Bauwerksnutzung oftmals eingeschränkt, sodass der Inspekteur mit Hilfe von technischen Geräten, wie Hubsteigern, das Bauwerk von Nahem inspizieren kann (vgl. Abb. 2). Erkannte Schäden sollen mit einem Foto und ihrer ungefähren Position dokumentiert werden. Diese handnahe Untersuchung ist sehr zeit- und kostenintensiv bei subjektivem sowie schwer reproduzierbarem Ergebnis.

Um diese visuelle Inspektion objektiver und mit reduziertem Personal-, Zeit- und Kostenaufwand durchzuführen, kann eine automatisierte Befliegung mittels Drohne bei zeitgleicher Fotodokumentation zur Unterstützung eingesetzt werden. Dabei liegen die Herausforderungen in der Automatisierung der Module zur Bauwerksbefliegung: Sowohl die an die Umgebung angepasste 3D-Flugplanung als auch die sichere Lokalisierung der Drohne sowie die Auswertung und die Bereitstellung der Daten werden automatisiert. Dieser Artikel stellt ein neu entwickeltes, vollständiges und modular aufgebautes System vor, mit dessen Hilfe alle Schritte von der Planung der Befliegung bis zur automatischen Auswertung und anschließenden Bewertung durchgeführt werden können. Aufgrund des modularen Aufbaus sind die entwickelten Methoden, die den einzelnen Phasen der automatischen Inspektion zugrunde liegen, auch unabhängig voneinander einsetzbar.

## 2 Stand der Technik

Der aktuelle Bauwerksbestand in Deutschland besteht zu einem großen Teil seit mindestens den 1960er Jahren und erfordert zwangsläufig eine regelmäßige und wiederkehrende Überprüfung sowie ein nachhaltiges Bauwerksmanagement, um den Qualitäts- und Sicherheitsstandards gerecht zu werden. Im Zuge dessen ist es essenziell und von zunehmender Bedeutung, dass Richtlinien qualitative und quantitative Vorgaben benennen, die eine einheitliche Erhaltung und Instandsetzung gewährleisten (Haardt 1997).

Für Ingenieurbauwerke wie Brücken und andere Konstruktionen im Verkehrsbereich gibt es mit der DIN 1076 sowie der DB Richtlinie 804 zwei rechtlich bindende Regelwerke, welche Prüfumfänge und Fristen genau regeln



Gierschner et al. 2021

Abb. 2: Manuelle Inspektion einer Halle



Schwandt 2017

Abb. 3: Blockierte Stahlkonstruktion im Halleninneren

(Deutsches Institut für Normung e.V. 1999a, DB Netz AG 2008).

Andere Bauwerke aus Stahl wie Hallen-, Industrie- oder Freizeitkonstruktionen unterliegen diesen nicht, sondern fallen unter die Richtlinie 6200 des Vereins Deutscher Ingenieure (VDI) (2010) mit Beurteilungs- und Bewertungskriterien für Bauwerke dieser Art. Die Richtlinie ist eine Handlungsempfehlung, keine verpflichtende Vorgabe, sodass die Durchführung von Inspektionen für den Baulastträger nicht nur einen Sicherheits-, sondern auch einen wirtschaftlichen Aspekt besitzt.

Studien zeigen, dass die Kombination von unbemanneten Flugobjekten (engl.: Unmanned Aerial System, UAS) mit der digitalen Bilderfassung eine Unterstützung bei der Inspektion von Infrastrukturbauwerken darstellt (Sperber und Gößmann 2016). Durch eine regelmäßige Befliegung der Tragstrukturen mittels UAS kann eine deutliche Verbesserung des Inspektionsstandards, welcher derzeit für die Qualität der bestehenden Bauwerke verantwortlich ist, erreicht werden. Erste Ansätze für die Unterstützung bei der Prüfung von Brücken durch UAS wurden beispielsweise im Projekt BetoScan untersucht (Dittmar 2016). Allerdings ist eine automatisierte UAS-Befliegung nur bei Verfügbarkeit eines globalen Navigationssatellitensystems (GNSS, z.B. Global Positioning System (GPS)) möglich, in Bereichen ohne GNSS erfolgt die Steuerung durch einen erfahrenen Piloten (Weinzierl 2020, Greenwood et al. 2019).

Insbesondere im Innenbereich kann sich das UAS an keinem Referenzsystem orientieren, sodass die Befliegung i. d. R. per Hand absolviert wird, was zur Vermeidung des Kollisions- bzw. Verletzungsrisikos hohe Ansprüche an den Piloten stellt (Niemeyer 2014).

Systeme zur Positionsbestimmung im Innenbereich sind derzeit Gegenstand der Forschung. Vor allem optische Verfahren, z.B. auf Basis von Kameras oder Lasersensoren, finden dabei Anwendung. Da kamerabasierte Systeme abhängig von der Umgebungsbeleuchtung, dem Sichtfeld sowie der Struktur der Oberflächen sind, kann eine sichere Lokalisierung unter den in Stahlhallen vorkommenden Umgebungsbedingungen nicht gewährleistet werden. Der Einsatz von laserbasierten Sensoren dagegen ermöglicht die Entfernungsbestimmung auch über größere Distanz und bei unzureichender Beleuchtung. Neben den 2D-Lokalisierungssystemen auf LiDAR-Basis (Light Detection and Ranging) wurden mit dem Aufkommen mobiler 3D-LiDAR-Sensoren in den letzten Jahren immer mehr 3D-Verfahren entwickelt (z. B. auf Basis von Partikelfiltern (Perez-Grau et al. 2017) oder der Merkmalsdetektion in Punktwolken (Shan et al. 2020)). Die Verwendung dieser 3D-Sensoren ist allerdings sehr gewichts- und rechenintensiv, sodass diese bei kompakten UAS-Systemen für die Inspektion im Innenraum nicht einsetzbar sind.

Derzeit erfolgen intensive Forschungen zu den technischen Verfahren und Möglichkeiten der Dronentechnologie, dennoch mangelt es an Forschung zur praktischen industriellen Anwendung (Maghazei und Netland 2019). Im Bereich der Inspektion gibt es beispielsweise Systeme zur automatisierten Prüfung von Brücken (Shanthakumar et al. 2020), Windenergieanlagen (Zhang et al. 2018) oder auch von Flugzeugen auf Basis von UAS (Mainblades 2021). Allerdings lassen sich diese Systeme nicht für den Einsatz für Inspektionen im Innenraum adaptieren, da die verwendeten Sensorsysteme für die Lokalisierung sehr schwer sind und eine hohe Rechenkapazität zur Verarbeitung der entstehenden Daten benötigen, sodass diese Systeme nicht mit kompakten UAS verwendet werden können und somit nicht für die automatisierte Inspektion komplexer und enger Umgebungen geeignet sind.

Die Auswertung von optischen Daten mittels Deep Learning wurde im Kontext der UAS- bzw. drohnenbasierten Inspektion von Bauwerken (Harweg et al. 2020) bzw. Fassaden (Kung et al. 2021), Brücken (Aliyari et al. 2021) und Stromtrassen (Ayoub und Schneider-Kamp 2021) bereits erfolgreich eingesetzt. Deep-Learning-Verfahren können einerseits zur Zustandsüberwachung von Gebäuden allgemein (Structural Health Monitoring) (Singh, Priyanka et al. 2020) angewendet werden, andererseits gibt es zahlreiche Beispiele für die Schadensprüfung in konkreten Anwendungsbereichen, u.a. für Betonkonstruktionen (Kim und Cho 2020) und Straßen (Doshi und Yilmaz 2020). Des Weiteren wurden Verfahren zur Schadenserkennung an Bauwerken (Structural Damage Detection) allgemein (Dhiraj et al. 2021), an Stahlkonstruktionen (Kim et al. 2021), Mauerwerk (Wang et al. 2018) und für spezifische

Schadensausprägungen (Cha et al. 2018) vorgeschlagen. Zudem wurden auch unüberwachte Lernverfahren bereits in diesem Bereich eingesetzt (Rastin et al. 2021). Eine Übersicht über Deep-Learning-basierte Verfahren einschließlich verschiedener Sensorik geben Azimi et al. (2020). Weitere verwendete Sensorik im Kontext des Schadensmonitorings mittels Deep Learning umfasst vibrations- (Won et al. 2021) oder ultraschallbasierte Ansätze (Melville et al. 2018).

In der hier vorgestellten Methode werden Deep-Learning-Verfahren zur bildbasierten Schadensdetektion in ein vollständiges System zur automatisierten Zustandserfassung von Bauwerken eingebettet. Die Schadensdetektion ist somit in dem entwickelten System keine losgelöste Erkennung von Einzelschäden, sondern Teil eines ganzheitlichen Bewertungssystems. Insbesondere ist somit eine genauere Bewertung möglich, da entdeckte Schäden hinsichtlich ihrer kritischen Eigenschaften für das Gesamtbauwerk bewertet werden können.

### 3 Automatisierte Inspektion

Bei routinemäßigen Inspektionen von Stahlhallen werden hauptsächlich tragende und sicherheitsrelevante Strukturen begutachtet. Diese Strukturen befinden sich zu großen Teilen in Bereichen, die ohne Nutzung von Hilfsmitteln außerhalb der Reichweite des Prüfpersonals liegen. Überwiegend sind die Beschädigungen oberflächlich, somit optisch detektierbar, und werden für die Bauwerksbewertung bestenfalls fotodokumentiert. Eine automatisierte Inspektion verlangt eine Prüfung der Gebäudebereiche, die insbesondere für die Standsicherheit relevant sind. Diese gilt es, im Vorfeld zu identifizieren und die Flugbahn des UAS so zu bestimmen, dass unter anderem die neuralgischen Bauwerksstrukturbereiche fotodokumentiert werden können. Der Einsatz von UAS für solche Inspektionen benötigt Verfahren zur 3D-Routenplanung auf Basis der Umgebungsbedingungen sowie ein sensorbasiertes Lokalisierungs- und Positionierungssystem. Auf den während der Befliegung aufgenommenen Fotografien der Bauwerksstruktur werden automatisch Schäden erkannt, klassifiziert und deren Ausmaß bestimmt. Diese Schadensparameter werden gemeinsam mit der Position des Schadens am Bauwerk zur Bauwerksbewertung herangezogen. Das Konzept zur automatisierten Inspektion stahlbaulicher Strukturen ist in Abb. 4 dargestellt und wird im Folgenden detailliert beschrieben.

#### 3.1 Befliegung eines Bauwerks zur Inspektion mittels Drohne

Bei stählernen Hallenkonstruktionen handelt es sich stets um unterschiedlich konstruierte, mit teuren und empfindlichen Maschinen gefüllte Innenräume und oftmals rauen

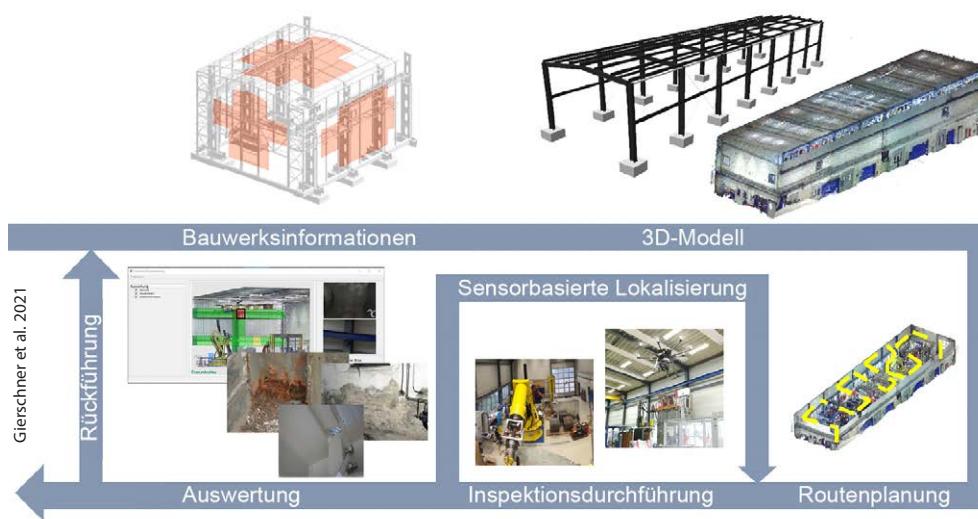


Abb. 4: Konzept zur drohnenbasierten Bauwerksinspektion

Umgebungsbedingungen, in denen kein GNSS-Signal vorhanden ist. Viele Konstruktionsstellen können durch die fest verbauten Produktionseinrichtungen gar nicht inspiziert werden (Abb. 3). Die konstruktiv relevantesten Bereiche sind für die hier durchgeführten Betrachtungen die Stützen und Dachhauptträger in den Ecken einer Halle sowie die mittleren Stützen bzw. Träger. Weitere wichtige Punkte sind die Fügepunkte zwischen den Stützen und Bindern aufgrund großer Stützmomente bei einer Rahmenkonstruktion sowie die Fußpunkte der Stützen. Folglich ist bei der Inspektion der Hauptträger sowie der Wandendeckung jeweils der mittige Bereich einer Stahlhalle zu priorisieren und zu fokussieren (ca. 30 % der Hallenbreite/-länge). Das Gleiche gilt für die Binder, Nebenträger sowie die Dacheindeckung der horizontalen Hallenflächen (in Abb. 5 farblich hervorgehoben). Diese unbedingt bzw. priorisiert zu inspizierenden Konstruktionsbereiche sind bereits bei der Inspektionsplanung bekannt und sind bei der Routenplanung entsprechend zu berücksichtigen. Dabei muss das zur Prüfung von Bauwerken eingesetzte Fluggerät einen Mindestabstand zur Konstruktion während des Einsatzes einhalten. Dieser dient der Sicherheit der Technik, vor allem aber können Personen und teure Maschinen gefährdet werden, sollte das Gerät nach einer Kollision mit der Konstruktion abstürzen.

Die Auswahl des UAS hängt von den Anforderungen ab, die durch den Einsatzzweck und die umgebende Struktur

definiert werden. So sind Parameter wie der Drohnen Typ, die Tragfähigkeit, die Größe und die maximale Flugdauer einige der entscheidenden Faktoren für die Auswahl der fliegenden Plattform. Die Dimensionierung des Sicherheitsabstandes wird außerdem von der Unsicherheit der Lokalisierung des UAS beeinflusst.

Der Einsatz eines UAS für Überwachung und Inspektion verlangt Verfahren zur 3D-Routenplanung entsprechend der

Umgebungsbedingungen sowie ein sensorbasiertes Lokalisierungs- und Positionierungssystem. Zur Erfüllung dieser Aufgaben werden 3D-Karten des Bauwerks benötigt, die die beflogbaren und nicht-beflogbaren Bereiche ausweisen. Eine 3D-Karte der Bauwerksstruktur kann anhand eines 3D-Modells (z.B. ein CAD oder eine Punktfolie) einer zu inspizierenden Halle erstellt werden. Durch eine gleichmäßige 3D-Rasterung dieses Modells in Voxel wird das Modell der Struktur vereinfacht, indem jeder Voxel als Teil der Bauwerksstruktur oder als beflogbar klassifiziert wird. Der Detaillierungsgrad der 3D-Karte hängt von der verwendeten Rasterweite ab.

Das Ziel einer Routenplanung ist die Bestimmung eines geeigneten kürzesten Weges durch das Bauwerk, den das UAS kollisionsfrei abfliegen kann. Eine detaillierte Darstellung des Bauwerkes ist nicht notwendig; lediglich der Durchmesser des UAS und der Sicherheitsabstand werden bei der Generierung der 3D-Karte für die Routenplanung berücksichtigt (siehe Abb. 6). Die 3D-Karte zur Positionsbestimmung hingegen muss einen hohen Detaillierungsgrad aufweisen. Eine solche wird durch Rasterung der Bauwerksstruktur mit kleiner Rasterweite generiert (siehe Abb. 7).

Eine Route wird durch eine Aneinanderreihung beflogbarer Voxel an deren Flächen repräsentiert. Um eine visuelle Inspektion der relevanten Bauwerksbereiche durchzuführen, führt die Route an den entsprechenden

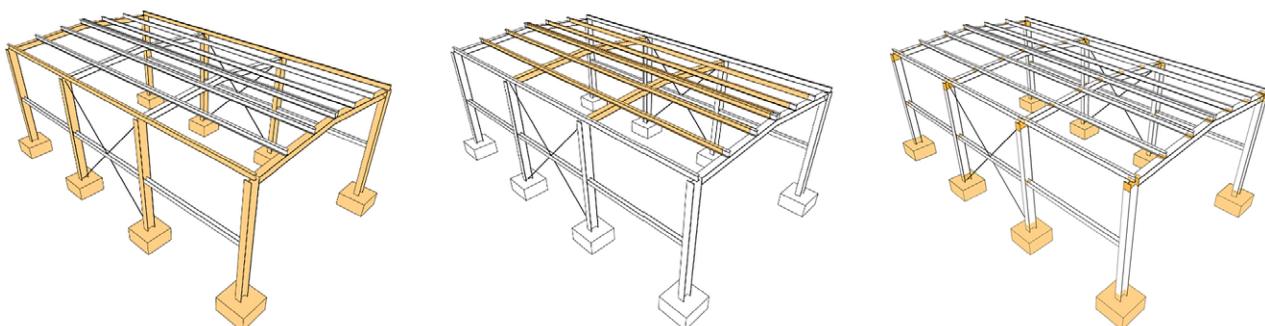


Abb. 5: Konstruktiv relevante Bauwerksbereiche (gelb markiert) einer üblichen Stahlhalle (nicht maßstäblich)

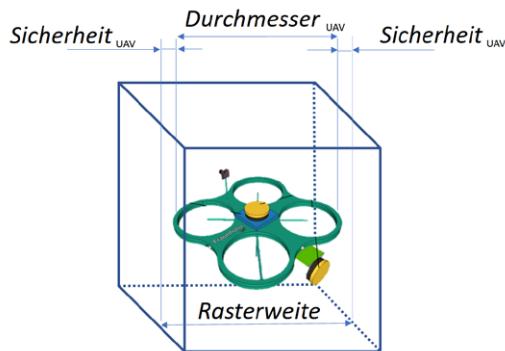


Abb. 6: Voxelgröße, bestimmt anhand UAS-Durchmesser und Sicherheitsabstand

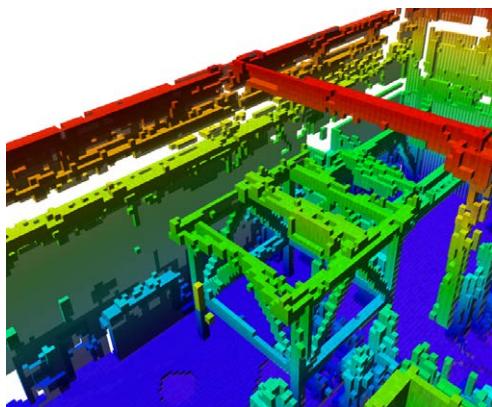


Abb. 7: Rasterung des 3D-Modells einer stählernen Halle mit einer Voxel-Kantenlänge von 200 mm, farbcodiert nach Höhenlage des Voxels

Bauwerksbereichen vorbei, indem die zu den Inspektionsstellen in Sichtlinie nächstgelegenen freien Voxel als obligatorischer Bestandteil der Route festgelegt werden. Die Gesamtroute enthält jeden dieser Voxel und den Start- und Zielvoxel. Es werden jeweils die kürzesten Strecken zwischen den obligatorisch zu befliegenden Voxel auf der binären 3D-Karte ermittelt (Distanztransformation (Soille 2003)). Die optimale Route entspricht der Lösung des Travelling-Salesman-Problems, bei der die Reihenfolge zu befliegender Voxel unter Berücksichtigung der ermittelten Einzelstrecke in einer kürzesten Route bestimmt wird (Schöning 2011).

Zur Inspektion soll das UAS im Start- und Zielvoxel losfliegen und der geplanten Route folgen. Dazu soll während der Befliegung die UAS-Position regelmäßig bestimmt und die Flugbahn entsprechend der Abweichung zur geplanten Route angepasst werden.

Da in und an Gebäuden eine solche Navigation mittels GNSS nicht möglich ist, muss für die Positionierung in Hallen auf die Kombination anderer Sensoren gesetzt werden. Diese Sensoren, sowohl einzeln als auch im Zusammenspiel als Multisensorsystem, sowie der verwendete Algorithmus zur Positionsbestimmung haben einen entscheidenden Einfluss auf die Genauigkeit und Robustheit der Steuerung. Anforderungen an das am Flugobjekt anzubringende Multisensorsystem sind Kompaktheit und geringe Masse.

Für die Lokalisierung wird ein System auf Basis von zwei leichten 2D-LiDAR-Sensoren sowie einer inertialen Messseinheit (engl.: Inertial Measurement Unit, IMU) vorgeschlagen, die zu einem 3D-Sensor fusioniert werden. Um die Position und Orientierung in der Umgebung zu bestimmen, wird ein LiDAR-Sensor am UAS horizontal und einer vertikal angeordnet. Dadurch lässt sich die 3D-Position sowie der Gierwinkel des UAS bestimmen, Nick- und Wankwinkel dagegen werden anhand der IMU bestimmt. Als Grundlage für die Positionsbestimmung dient ein Verfahren zur direkten Abstands- und Orientierungsbestimmung der Sensordaten in Bezug zur Umgebungskarte mittels eines 3D-Distanzfeldes (Direct Lidar Localization, DLL (Caballero und Merino 2021)). Zur Vorausrichtung der Sensordaten und damit zur Optimierung der Lokalisierung innerhalb der Umgebungsdaten wird die Schätzung der Bewegung als Grundlage für die Lokalisierungsalgorithmen (Odometrie) anhand eines Scan-Matching-Verfahrens auf Basis der iterativen Punktannäherung (Besl und McKay 1992) genutzt. So wird das entwickelte Sensorsystem auf Basis von 2D-LiDAR-Sensoren sowohl für die Bewegungsschätzung als auch für die Lokalisierung innerhalb der merkmalsbasierten Umgebungskarte verwendet (Gierschner 2021).

Während der Befliegung entlang der geplanten Route erfolgt die Datenaufnahme der Umgebung für die automatisierte Bauwerksbewertung. Die Bild- und ggf. weiteren Sensordaten werden dabei entsprechend der Position des UAS mit der Kameraorientierung sowie dem geschätzten Abstand zum Objekt der Route zugeordnet.

### 3.2 Automatisierte Auswertung der Inspektionsdaten

Die Auswertung der per UAS erfassten Daten umfasst drei wesentliche Punkte: Die Festlegung der zu erkennenden Schäden, samt Kriterien zur Bewertung und den damit verbundenen Anforderungen an die Erfassung, die automatische Erkennung mittels KI-basierter Methoden (Künstliche Intelligenz) sowie schließlich die Rückführung der Resultate in die Bewertung des Bauwerkszustands. Diese Punkte werden im Folgenden detailliert beschrieben.

Anhand der während der UAS-Befliegung aufgenommenen Bilddaten soll das Bauwerk hinsichtlich der Baustruktur bewertet werden. Die Auswertung der Bilddaten im Anschluss an die Befliegung ist nur mit hinreichend genauen Positionsdaten möglich, um erkannte Schäden der Stelle ihres Auftretens zuzuordnen. Die Schäden werden hierbei automatisiert mit KI-gestützten Algorithmen erkannt und auf Basis ihrer Art und Position innerhalb der konstruktiven Hallenstruktur zur Bewertung des Bauwerks herangezogen. Dies erfordert neben der Definition eines Schadens auch eine jeweils eigene schadensspezifische Bewertung. Diese ist von der Art des Schadens, der Lokalisation und der Größe abhängig, sodass für jede Schadensart und -ausprägung hinsichtlich ihres Auftritts-ortes eine Bewertung zu hinterlegen ist, mit welcher eine

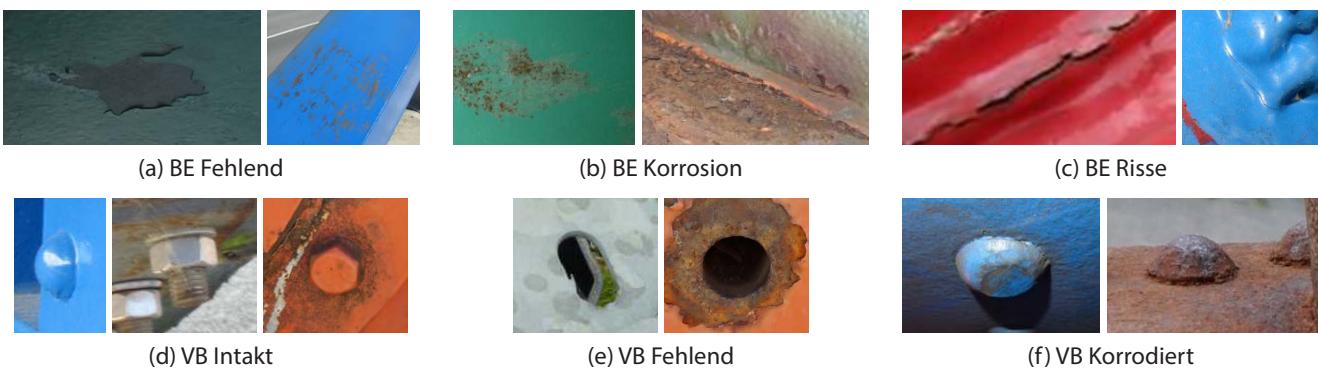


Abb. 8: Beispielhafte Schadensausprägungen für die Klassen der Kategorien (a) – (c) Beschichtung (BE) und (d) – (f) Verbindungsmittel (VB)

Gesamtbewertung der stählernen Bauwerksstruktur berechnet werden kann, da hier nicht auf die Einschätzung eines erfahrenen Prüfingenieurs zurückgegriffen werden kann. Die häufigsten Bauwerksschäden sind den Kategorien Korrosion, Verbindungsmittel, Risse, Dreck, Moos, Graffiti und Kot zuzuordnen (siehe Abb. 8). Für diese werden jeweils zwei Schweregrade der Schädigung anhand quantifizierbarer Ausprägungen ermittelt: Flächenschäden kleiner bzw. größer als  $5 \text{ cm}^2$ , Rissbreitenschäden mit  $4 \text{ mm} < t \leq 6 \text{ mm}$  oder größer und mehr bzw. weniger als drei fehlende Verbindungsmittel.

Die Auswertung der Bilddaten erfolgt mit einem Verfahren aus dem Bereich der Convolutional Neural Networks (CNN). Hierbei handelt es sich um maschinelle Lernverfahren, welche auch unter dem Oberbegriff Deep Learning zusammengefasst werden. Für Problemstellungen, welche die Erkennung und Interpretation von Bildinhalten umfassen, stellen Verfahren aus dem Bereich der CNN aktuell die mit Abstand leistungsfähigsten Verfahren dar (vgl. Jiao und Zhao 2019, O'Mahony et al. 2020). Als maschinelles Lernverfahren besteht das Grundprinzip darin, den Lösungsweg aus Beispieldaten zu erlernen, im Gegensatz zu einer manuellen Definition von Kriterien oder Regeln. Eine Besonderheit der CNN ist hierbei, dass auch Bildmerkmale, wie z. B. Kanten-, Farb- oder Texturmerkmale, automatisch erlernt werden können.

Die hier vorgestellte Analyse von Schäden bzw. schadhaften Stellen der in den Bilddaten abgebildeten Bauteile besteht aus mehreren Teilespekten. Zunächst muss untersucht werden, ob ein Schaden vorhanden ist. Ist dies der Fall, muss dieser lokalisiert werden, wobei sich die Lokalisierung hier zunächst ausschließlich auf die Position innerhalb des Bildes bezieht. Zudem ist die Klassifikation, um welchen Schaden es sich handelt, erforderlich. Technisch gesehen entspricht diese Gesamtproblemstellung der semantischen Objektdetektion bzw. Instanz-Segmentierung, wobei Letztere zusätzlich eine pixelgenaue Einteilung der erkannten Objekte beinhaltet. Hier wird die Mask-RCNN-Methode (Region-CNN) (He et al. 2017) zur Lösung der semantischen Instanz-Segmentierung gewählt. Im Detail wurde das Mask-RCNN mit ResNet-50 Backbone (He et al. 2016) und Feature Pyramid Network (Lin, T. et al. 2017) verwendet, die genutzte Implementierung basiert auf

Detectron2 (Wu et al. 2019). Der zugrundeliegende Datensatz besteht aus manuell annotierten Bilddaten, welche zu großen Teilen aus händisch durchgeführten Brückenprüfungen<sup>3</sup> stammen. Auf Basis des entwickelten Schadenskatalogs wurde eine möglichst deckungsgleiche Einteilung der dargestellten Schäden in Klassen vorgenommen, welche zur Verarbeitung durch das CNN geeignet sind. Für eine bessere Übersichtlichkeit und aufgrund der Tatsache, dass die Anwendung des Verfahrens im Wesentlichen unverändert bleibt, wird für die Auswertung hier eine Teilmenge dieses Katalogs verwendet. Diese umfasst Tragkonstruktionen (TK), Verbindungsmittel (VB) sowie Beschichtungsfehler, einschließlich Risse (BE). Die Auswertung erfolgt für diese drei Kategorien, für die jeweils ein geeigneter Datensatz auf Basis der annotierten Bilddaten erstellt wurde. Während die Klasse TK nur aus einem Element besteht, gibt es bei VB die weitere Einteilung in *Intakt*, *Fehlend* sowie *Korrodiert* und bei BE in *Fehlend*, *Korrosion* sowie *Risse*. Einige Beispiele für die Ausprägung der Schäden in den jeweiligen Schadensklassen sind in Abb. 8 gezeigt. Der Datensatz besteht aus insgesamt ca. 5400 Bildern, aus denen für jede Kategorie eine Teilmenge verwendet wird.

Für das Training wird zudem auf ein bereits auf anderen Daten vortrainiertes Netz zurückgegriffen, um die Erkennungsgenauigkeit zu steigern, bei gleichzeitig geringerer Trainingszeit (»Transfer Learning«, vgl. Torrey und Shavlik 2010, Yosinski et al. 2014). Um eine größere Varianz der Trainingsdaten und damit eine höhere Genauigkeit bzw. Robustheit bei der Erkennung zu erzielen, werden während des Trainingsprozesses verschiedene Augmentierungen (Spiegelung, Hoch- und Tiefpassfilter, Helligkeits- und Kontrastanpassungen sowie künstlich erzeugtes Rauschen) auf die Daten angewendet (vgl. Shorten und Khoshgoftaar 2019). Durch Augmentierung werden die vorhandenen Trainingsdaten derart modifiziert und erweitert, dass eine ursprünglich nicht repräsentierte, aber trotzdem wahrscheinliche Variation derselben erzeugt wird. Die Entscheidung, ob eine (oder mehrere) Transformationen angewendet werden, wird in jeder Trainingsiteration zufällig getroffen.

<sup>3</sup> Bilder mit Genehmigung von PSP – Prof. Sedlacek & Partner, Planung und Entwicklung im Bauwesen, Büro Dortmund

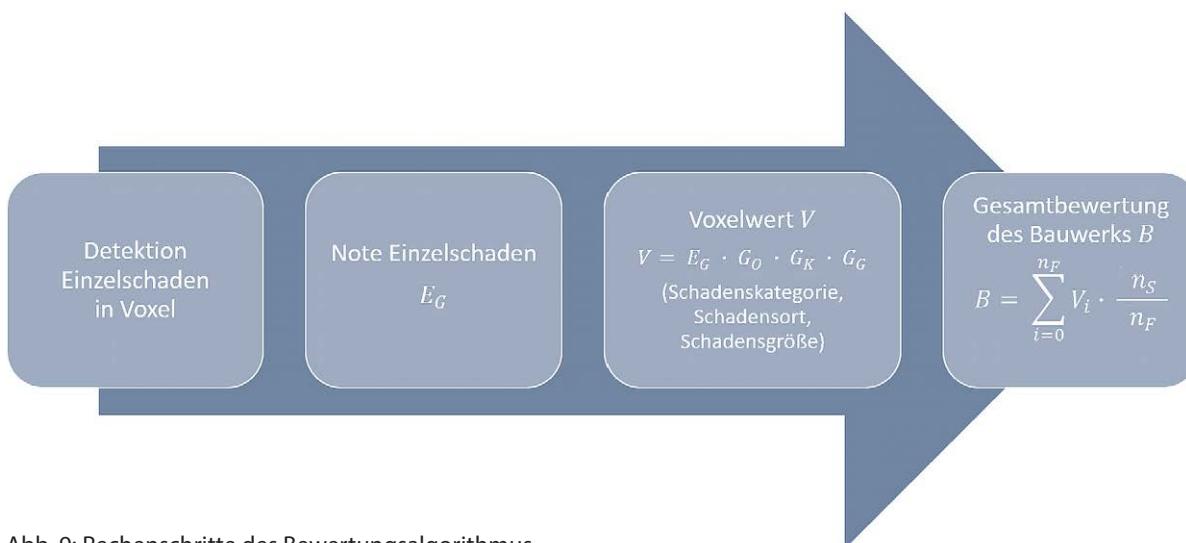


Abb. 9: Rechenschritte des Bewertungsalgorithmus

Die für die Bewertung der erkannten Schäden essenzielle tatsächliche Schadensgröße lässt sich mit der Ground Sample Distance (GSD) – ein Maß zur Umrechnung von der Größe eines in der Aufnahme dargestellten Objekts in Pixeln zur realen Größe in Metern – bei bekannten in- und extrinsischen Kamera-Parametern direkt bestimmen. Während die intrinsischen Kamera-Parameter vor der Befliegung fixiert werden, werden die extrinsischen Kamera-Parameter, in denen die Lage des Bildobjektes zur Kamera beschrieben wird, aus voxelgenauer Kameraposition bei Bildaufnahme und aufgenommenem Voxel approximiert. Aus der näherungsweise bestimmten GSD kann die reale Größe der detektierten Schäden geschätzt werden.

Bei der Bewertungsfindung ist die Anlehnung an das bestehende System der DIN 1076 zu wahren, um eine zukünftige Einbindung z.B. in SIB-Bauwerke (WPM Ingenieure 2001), der bundesweit verpflichtend einzusetzenden Softwarelösung für Brückenprüfungen nach DIN 1076, zu gewährleisten. Entsprechend der zuvor definierten, möglichen Schädigungen der Tragstruktur wird jedem Schaden eine »Note des Einzelschadens«  $E_G$  (Zahlenwert ohne Einheit) zugeordnet. Nachfolgend erhält jeder Voxel  $i$ , in dem sich mindestens ein Schaden befindet, einen Voxelwert  $V_i$ , welcher sich aus  $E_G$  (Zahlenwert ohne Einheit) und drei Gewichtungsfaktoren entsprechend der Schadensoberkategorie ( $G_O$ , Zahlenwert ohne Einheit), -größe ( $G_G$ , Zahlenwert ohne Einheit) und -position in der Konstruktion ( $G_K$ , Zahlenwert ohne Einheit) zusammensetzt. Bei mehr als einem Schaden pro Voxel ist derjenige mit dem größten  $E_G$  ausschlaggebend. Die Kategorien »Verbindungen« und »Risse« sind für das Tragwerk von größter Bedeutung ( $G_O = 1,0$ ). Korrosions- und Beschichtungsschäden sind weniger gefährlich für die Standsicherheit ( $G_O = 0,7$ ), während Schäden der Kategorie »Moos, Graffiti, Dreck und Kot« den geringsten Einfluss nehmen ( $G_O = 0,3$ ). Schäden, welche an kritischen Punkten im Tragwerk gefunden wurden, erhalten eine höhere Gewichtung ( $G_K = 0,9$ ) als Schäden an weniger neuralgischen konstruktiven Stellen ( $G_K = 0,4$ ). Ein Schaden der zuvor definierten großen Schadensausprägung wird mit  $G_G = 0,9$ , ein kleiner Scha-

den mit  $G_G = 0,5$  gewichtet (Berechnungsschema in Abb. 9 dargestellt). Die Summe aller Voxelbewertungen wird zur Gesamtbewertung des Bauwerks  $B$  (Zahlenwert ohne Einheit) herangezogen,

$$B = \sum_{i=0}^{n_F} V_i \cdot \frac{n_S}{n_F},$$

wobei außerdem die Anzahl aller beflogenen Voxel  $n_F$  sowie die Anzahl der Voxel mit Schädigungen  $n_S$  berücksichtigt werden.

## 4 Umsetzung und Ergebnisse

Das konzeptionierte Inspektionssystem ist modular aufgebaut. Die Komponenten können ihre Aufgabe im Gesamtsystem, bei Vorlage geeigneter Daten, also unabhängig voneinander ausführen. Im Folgenden werden das Inspektionssystem, die Routenplanung und Navigation sowie die KI-gestützte Schadenserkennung im Detail ausgewertet.

### 4.1 Trägerplattform für das Inspektionssystem

Für den praktischen Einsatz und zur Erprobung des entwickelten Verfahrens erfolgte die prototypische Umsetzung des Inspektionssystems. Neben dem Multisensorsystem zur Lokalisierung muss das UAS-System die Inspektionssensorik tragen können. Für die Schadensdokumentation dient eine digitale spiegellose Systemkamera mit einer Auflösung von ca. 24 Megapixeln ( $6000 \times 4000$  Pixel und einer Sensorzelle der Größe  $3,9 \mu\text{m}$ ) bei einem Gewicht von unter 350 g (Sony Europe B. V. o. D.). Dadurch kann die sichere Schadenserkennung entsprechend der Umgebungsbedingungen (z.B. Lichtverhältnisse, Vibrationen) gewährleistet werden. Für die Lokalisierung werden leichte 2D-LiDAR-Sensoren mit einem Gewicht von ca. je 130 g verwendet. Als geeignete Trägerplattform dient ein Octocopter vom

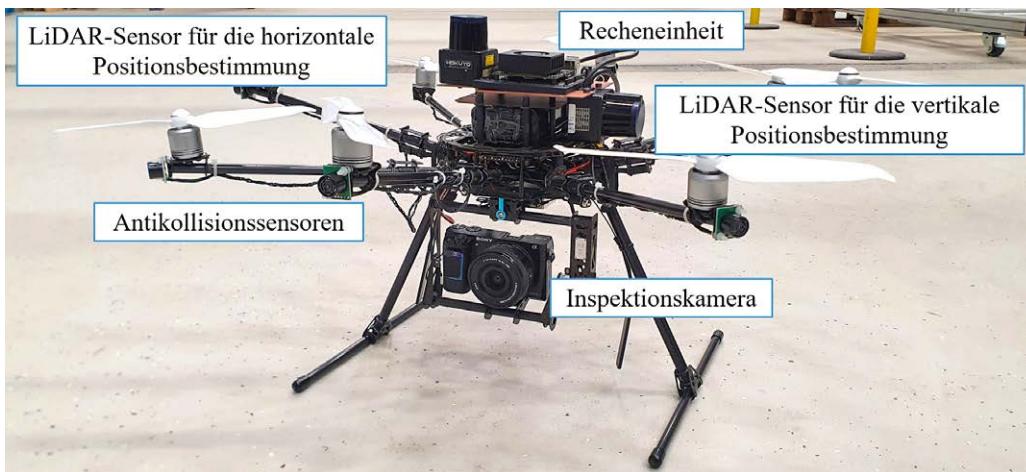


Abb. 10:  
Inspektionsplattform:  
Octocopter mit Lokali-  
sierungs- und Inspek-  
tionssensorik

Typ CIS Oktopus (Abb. 10). Dieser hat eine Diagonale von ca. 75 cm, verfügt über eine maximale Nutzlast von 700 g und kann mit einem Akku bis zu 45 min fliegen.

#### 4.2 Routenplanung und Navigation

Die Routenplanung und die Positionsbestimmung wurden in der gleichen Beispielhalle mit den Abmessungen 31 m × 16 m × 12 m getestet. Mit einem terrestrischen Laserscanner (Faro Focus X130 3D, Systematischer Distanzfehler:  $\pm 2 \text{ mm}^4$ ) wurde diese Halle als 3D-Punktwolke digitalisiert. Dafür wurde die Halle von mehreren Standpunkten gescannt und die Einzelscans zu einer Gesamt punktwolke registriert.

Zur Generalisierung der 3D-Punktwolke für die Routenplanung wurde die Rasterweite mit 2 m gewählt. Entlang zweier gegenüberliegender Stahlträger wurden zu inspizierende Voxel mit und ohne Priorität festgelegt (siehe Abb. 11, orange und blau) und ein geeigneter Bereich am Boden der Halle wurde als Start- und Zielvoxel der Route

<sup>4</sup> Quelle: Datenblatt unter <https://pdf.directindustry.de/pdf/faro-europe/technische-spezifikationen-faro-laser-scanner-focus3d-x-130/21421-25051.html>, letzter Zugriff 10.07.2023

vorgegeben. Die berechnete Route ist in der gleichen Abbildung durch violette Voxel dargestellt.

Die Eignung des entwickelten Lokalisierungssystems für den Einsatz bei der UAS-basierten Inspektion von Hallen lässt sich mit einer Genauigkeitsuntersuchung unter anwendungsnahen Umgebungsbedingungen nachweisen, die an das Verfahren zur Prüfung von Industrierobotern entsprechend der Norm ISO 9283 (Deutsches Institut für Normung e. V. 1999b) angelehnt ist. Das entwickelte Sensorsystem auf Basis eines Distanzfeldes (DLL-Algorithmus) wird dabei auch mit weiteren 3D-Lokalisierungsverfahren verglichen und entsprechend der erreichten Genauigkeit bewertet. Zum einen mit der Lokalisierung auf Basis von iterativer Punktannäherung (ICP, engl.: Iterative Closest Point), deren Grundlagen von Besl und McKay (1992) entwickelt wurden, und zum anderen mit einer stochastischen Zustandsschätzung (AMCL, adaptive Monte-Carlo-Lokalisierung), die Perez-Grau et al. (2017) vorschlagen. Die experimentelle Untersuchung wurde anhand einer Versuchsstrecke von insgesamt ca. 70 m je Messreihe in einer Beispielhalle realisiert. Dabei zeigte sich, dass das entwickelte System eine Absolutgenauigkeit von 110,5 mm und eine Wiederholgenauigkeit von 134,0 mm erreicht und damit für die sichere Befliegung in komplexen Umgebungen geeignet ist. Die Vergleichssysteme dagegen ermöglichen

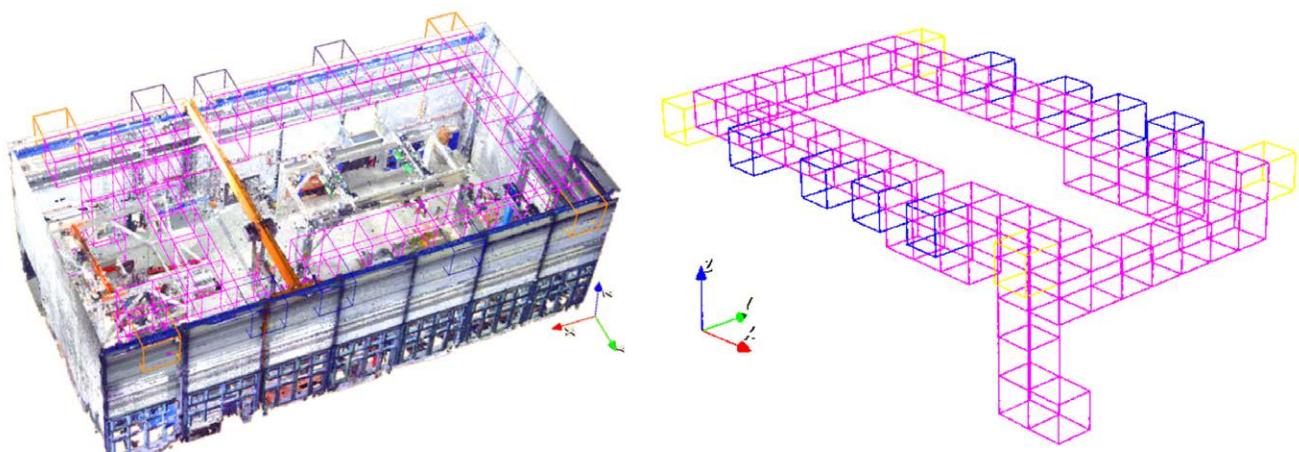


Abb. 11: Beispielroute zur Inspektion eines Stahlträgers, links: innerhalb der Beispielhalle, rechts: Routenvoxel (violett) und Inspektionssvoxel (gelb und blau) extrahiert

Tab. 1: Ergebnisse der Genauigkeitsuntersuchung des Multisensorsystems in Millimeter (Gierschner 2021)

	2D-LiDAR-Odometrie			3D-Stereokamera-Odometrie		
	DLL	ICP	AMCL	DLL	ICP	AMCL
Mittlere Abweichung	111,0	959,6	1399,2	136,8	283,5	355,6
Standardabweichung	40,6	370,2	568,2	54,2	236,1	147,3
Maximale Abweichung	191,3	1573,1	2266,6	219,8	719,1	533,3

nur eine ungenauere Bestimmung der Position. Die Ergebnisse zeigt Tab. 1. Neben dem Vergleich der 3D-Lokalisierungsverfahren wurden auch verschiedene Methoden zur Schätzung der Bewegung (Odometrie) als Grundlage für die Lokalisierungsalgorithmen untersucht, zum einen eine 2D-Schätzung auf Basis eines 2D-LiDAR-Sensors und zum anderen eine 3D-Schätzung auf Basis einer Stereokamera. Mit der Versuchsdauer von über 30 Minuten lässt sich ebenfalls die robuste Lokalisierung des Sensorsystems über die für die Inspektion einer standardisierten Produktionshalle benötigte Zeit nachweisen (Gierschner 2021).

#### 4.3 Schadensanalyse mittels KI

Während der Befliegung werden zu jedem erfassten Foto der fotografierte Voxel und die UAS-Position gespeichert. Das aufgenommene Bildmaterial wird anschließend hinsichtlich der zuvor definierten möglichen Schädigungen analysiert. Dies erfolgt analog zu der vorgestellten Analyse (vgl. Abschnitt 3).

Ein Vorteil des zugrundeliegenden Deep-Learning-Verfahrens ist, dass die Schadensdetektion durch erneutes Training des Mask-RCNN mittels geeigneter Datensätze auf weitere Schadensklassen angepasst werden kann. Durch das Verfahren wird ermittelt, ob in dem gegebenen Bild ein Schaden vorliegt, um welche Schadensart es sich handelt und an welcher Stelle im Bild sich selbiger befindet.

Die Auswertung erfolgte anhand des in Abschnitt 3 beschriebenen Datensatzes, unterteilt in die Kategorien Verbindungsmittel (VB), Beschichtungsfehler (BE) sowie Tragkonstruktionen (TK). Die verwendeten Datensätze umfassen hierbei für TK 1000 Bilder mit insgesamt 1430 annotierten Objekten, für BE 1371 Bilder mit 6649 annotierten Objekten und für VB 464 Bilder mit 4986 annotierten

Objekten. Die Unterteilung erfolgt jeweils in Anteile von 0,8/0,1/0,1 für Training, Validation und Test. Das Mask-RCNN wurde schließlich über eine moderate Anzahl von 30.000 Iterationen bei einer Lernrate von  $10^{-4}$  trainiert.

Die Bewertung der Ergebnisse erfolgte anhand der (Mean) Average Precision (mAP bzw. AP), die Teil der verwendeten COCO-Metrik (Lin, T.-Y. et al. 2014) ist. Die AP-Metrik kann als Erweiterung des Precision/Recall-Schemas für binäre Klassifikatoren auf das Problem der Objektdetektion bzw. semantischen Segmentierung aufgefasst werden (Everingham et al. 2010). Die Grundlage zur Berechnung bildet hierbei die Intersection over Union (IoU), die sich auf Basis der detektierten und der tatsächlichen (annotierten) Lage der zu erkennenden Objekte berechnet und das Verhältnis der Überschneidung (Intersection) zu Vereinigung (Union) der jeweilig zugehörigen Flächenmaße darstellt. Als korrekt erkannt werden hierbei üblicherweise Detektionen mit einem IoU-Wert von  $\geq 0,5$  angesehen (He et al. 2017). Die COCO-Metrik umfasst verschiedene Werte, von denen hier AP und AP<sub>50</sub> verwendet werden. AP<sub>50</sub> bezeichnet den direkten Wert aus den Überschneidungen mit mindestens 50 %, während AP einen Mittelwert aus der Berechnung mit schrittweise erhöhten Mindestwerten bezeichnet.

Tab. 2 zeigt die Erkennungsgenauigkeit für die jeweiligen Klassen. Dort sind neben dem AP-Wert die entsprechenden klassenspezifischen Werte sowie der AP<sub>50</sub>-Wert eingetragen.

Bei der Erkennungsgenauigkeit sind deutliche Unterschiede festzustellen. Während Tragkonstruktionen mit AP<sup>TK</sup> = 50,7 recht zuverlässig erkannt werden<sup>5</sup>, ist die

5 Vgl. z. B. die Bestwerte bzgl. des COCO-Datensatzes unter <https://cocodataset.org/#detection-leaderboard>, letzter Zugriff 27.01.2023

Tab. 2: Erkennungsgenauigkeit (AP) in Prozent für die Schadensklassen Tragkonstruktion (TK) sowie Beschichtung und Verbindungsmittel auf Gesamtbildern (BE bzw. VB) und Ausschnitten (BE<sub>bb</sub> bzw. VB<sub>bb</sub>)

	AP	AP <sub>50</sub>	AP <sub>Fehlend</sub>	AP <sub>Korrosion/Korrodiert</sub>	AP <sub>Intakt</sub>	AP <sub>Riss</sub>
TK	50,7	65,4	–	–	–	–
VB	28,1	50,6	14,7	34,9	34,7	–
VB <sub>bb</sub>	61,3	80,5	41,5	72,7	70,0	–
BE	8,6	17,1	11,5	11,1	–	3,3
BE <sub>bb</sub>	49,5	83,2	43,3	58,8	–	46,4

allgemeine Rate bei Verbindungsmitteln mit  $AP^{VB} = 28,1$  deutlich geringer und fällt bei Beschichtungsfehlern mit  $AP^{BE} = 8,6$  noch stärker ab. Diese Unterschiede und die teilweise unzureichenden Erkennungsraten sind insbesondere auf die Charakteristik der Bilddaten zurückzuführen. Da der Ausgangsdatensatz zu großen Teilen Bilder der Gesamtkonstruktionen enthält, ist vor allem die Lokalisierung der Schäden eine Herausforderung, was sich in den im Vergleich zu AP höheren Werten von  $AP_{50}$  widerspiegelt.

Um die bestehende Datenbasis entsprechend der Charakteristik der Aufnahmen einer Drohnenbefliegung anzugelichen, wurden in einer zweiten Auswertungsreihe neue Bilddaten aus den bereits vorhandenen erzeugt. Hierfür wurde jeder in einem Bild vorhandene Schaden in einem rechteckigen Bereich der direkten Umgebung automatisiert ausgeschnitten und als Einzelbild gespeichert. Die Gesamtheit dieser Ausschnitte bildet den Datensatz dieser Auswertungsreihe ( $BE_{bb}$  6649 Bilder,  $VB_{bb}$  4986; direkt der Anzahl der Annotationen entsprechend). Somit kann die Detektion auf die Schäden an sich fokussiert werden und störende Einflüsse wie Bildhintergründe der Umgebung, die nicht Gegenstand der Untersuchung sind, können ausgeschlossen werden. Die Datensätze sind, analog zur vorherigen Namenskonvention, mit  $VB_{bb}$  sowie  $BE_{bb}$  bezeichnet (nach engl. »Bounding Box«), die jeweiligen Schadensklassen bleiben bestehen. Die bisherigen Trainingsparameter wurden beibehalten.

Ebenfalls in Tab. 2 ist die Erkennungsgenauigkeit der schadensspezifischen Bildausschnitte gezeigt. Hierbei sind sowohl für Verbindungsmittel mit  $AP^{VB_{bb}} = 61,4$  bzw.  $AP_{50}^{VB_{bb}} = 80,5$  als auch für Beschichtungsfehler mit  $AP^{BE_{bb}} = 49,5$  und  $AP_{50}^{BE_{bb}} = 83,2$  deutlich höhere Erkennungsraten zu verzeichnen. Auch die klassenspezifischen Genauigkeiten sind deutlich erhöht. Für z.B. Beschichtungen steigt die Genauigkeit für die Kategorie *Riss* sehr deutlich von 3,3 auf 46,4, aber auch für *Fehlend* und *Korrosion* sind die Werte von 11,5 auf 43,5 bzw. von 11,1 auf 58,8 deutlich erhöht. Dies zeigt, dass insbesondere die Erkennung der Schadensklassen mit hoher Genauigkeit möglich ist. Anzumerken ist hierbei auch, dass die gewählten Schadensklassen nicht vollständig disjunkt sind. So können sowohl bei Verbindungsmitteln als auch bei Beschichtungsfehlern die Kriterien für die Kategorien »fehlend« und »korrodiert« gleichzeitig erfüllt sein. Da die Objekte für die Klassifikation durch das CNN genau einer Klasse zugeordnet werden müssen, verbleibt hier eine Ungenauigkeit. Auch die Ausprägung der Schäden kann, vor allem bei Beschichtungsfehlern, stark variieren. Korrosion z.B. kann lokal konzentriert, großflächig oder in einer Zwischenform auftreten. Eine feingranularere Einteilung mittels weiterer Kategorien wäre hierbei grundsätzlich denkbar, jedoch konzeptionell und in der Umsetzung mit erheblichem Zusatzaufwand verbunden.

## 5 Bewertung und Diskussion

Durch den modularen Aufbau lassen sich die Komponenten einzeln oder auch in Verbindung mit anderen Systemen verwenden. Dies eröffnet den Einsatz in vielen Anwendungsbereichen, wie der Navigation von fahrerlosen Transportfahrzeugen und der Erkennung von anderen Schadensarten und Materialien.

Die Routenberechnung erfolgt ausschließlich anhand des generalisierten 3D-Bauwerkmodells, weitere UAS-Parameter wie die Akkulaufzeit werden derzeit noch nicht berücksichtigt. Deshalb sollte vor einer Befliegung die berechnete Route kritisch hinsichtlich Länge und Komplexität betrachtet werden. Neben der zusätzlichen Traglast durch die Sensorik und andere Hardware wirken sich auch die Flugmanöver auf die Akkulaufzeit aus. Die Routenplanung allein genügt nicht zur Sicherstellung der Kollisionsfreiheit, da dabei Personen und bewegliche Objekte nicht berücksichtigt werden. Aus diesem Grund wurden zusätzliche Ultraschallsensoren auf dem System installiert. Nähert sich dem UAS ein Hindernis, bleibt es stehen bzw. weicht in entgegengesetzte Richtung aus. Diese Reaktion ergänzt die Sicherheitsaspekte in der eigentlichen Navigation.

Durch die Verknüpfung eines 3D-Lokalisierungsverfahrens mit einer 2D-Positionsschätzung auf Basis der 2D-LiDAR-Odometrie sowie der Inertialsensoren können die Positionsdaten ausreichend schnell und genau für die Lokalisierung bereitgestellt werden. Dadurch entsteht ein leichtes und kompaktes Sensorsystem mit geringem Rechenbedarf gegenüber 3D-Sensoren als Grundlage für die Navigation, das mit kompakten UAS-Systemen auch für die Inspektion von Stahlhallen geeignet ist.

Für den Einsatz in Umgebungen, die die Verknüpfung von Innen- und Außenbereich erfordern, kann die Karte, und somit die Route, ins GNSS-Koordinatensystem transformiert und die lokal bestimmte Position durch die GNSS-Schnittstelle eingespeist werden.

Die Ergebnisse zeigen, dass die KI-basierte Schadenserkennung geeignet ist, die Schäden sowohl zu lokalisieren als auch zu unterscheiden. Im Falle der hier durchgeföhrten optischen Erfassung ist eine entsprechende Unterscheidbarkeit auf Basis dieser Sensorik eine grundlegende Voraussetzung. Gleichzeitig ist bereits das verwendete Mask-RCNN-Verfahren nicht auf optische Sensorik beschränkt und kann auch auf andere Quellen angepasst werden, sofern die Daten sich in eine geeignete Form transformieren lassen. Für eine gute Erkennung der Schäden ist eine gute Datenbasis erforderlich. Diese muss idealerweise Beispiele aller vorkommenden Schäden gut abdecken und gleichzeitig eine möglichst ähnliche Charakteristik aufweisen.

Voraussetzung für eine zuverlässige Erkennung der Schäden ist zudem eine hohe und gleichbleibende Aufnahmegerualität. Um dies zu gewährleisten, ist es erforderlich, relevante Parameter und störende Einflüsse wie Lichtverhältnisse zu optimieren. Dahingehende Optimierungen werden Gegenstand zukünftiger Studien sein. Für eine akkurate Schätzung der tatsächlichen Schadensgröße ist

zudem eine möglichst genaue Bestimmung der GSD erforderlich. Hier ist der Einsatz einer gerichteten Abstandssensorik denkbar.

Das Erzeugen einer Gesamtnote für die Inspektion des Bauwerks, in Anlehnung an ein bestehendes Bewertungssystem der DIN 1076 für Brückenbauwerke, ist generell kritisch zu betrachten. Eine Gesamtnote macht das objektive Vergleichen vieler Bauwerke möglich, um eine Priorisierung der Instandsetzungen festzulegen. Jedoch ist jedes Bauwerk stark different, mit vielen Spezialkonstruktionen und Eigenheiten versehen, sodass das Herunterbrechen des Gesamtzustands auf eine Gesamtnote den wahren Bauwerkszustand verfälscht. Eine Vergleichbarkeit der Endnoten ist nur bei ähnlichen Bauwerksstrukturen gegeben. Die hier ermittelte Gesamtbewertung durch den Bewertungsalgorithmus zeigt diese Problematik. Ein sichereres Ordnen der Endnoten für die Vergleichbarkeit verschiedener Bauwerke untereinander ist zum jetzigen Stand nicht gänzlich gegeben. Dennoch ermöglicht das Bewertungssystem, ein immer gleiches Bauwerk über den zeitlichen Verlauf zu überprüfen, da Schädigungen sicher wiedergefunden und somit stetig beobachtet werden können. Eine Analyse der Veränderungen zwischen zwei Inspektionen ist hiermit garantiert. Die optische Enddarstellung der Ergebnisse durch verschiedenfarbige Voxel, welche die Lokalisation sowie die Größe eines Schadens anzeigen, sind für den Bauwerksprüfer bzw. Bauherren hilfreicher als eine Bewertung in Form eines Zahlenwerts.

Für die vorgestellte Methode ist keine (stationäre) Installation von Sensorik nötig. Der Einsatz wird hier an der Inspektion von Hallen demonstriert, ist jedoch grundsätzlich für verschiedenste Gebäudetypen geeignet. Ziel des Verfahrens ist zudem, in Einklang mit bestehenden Prüfnormen zu bleiben.

Anhand der hier untersuchten Verfahren konnte gezeigt werden, dass bei einer Bauwerksbefliegung mittels UAS immer die konstruktiv relevantesten Punkte inspiert werden können, und diese somit die Art der Bauwerksinspektion, wie sie für Brückenbauwerke vorgeschrieben ist, in Form von laufenden Beobachtungen oder jährlichen Besichtigungen unterstützen bzw. intensivieren kann. Es könnte eine beispielsweise jährliche Befliegung von Hallenstrukturen stattfinden, um hier Prüfintervalle zu reduzieren. Eine vollumfängliche Betrachtung aller Bauteile ist derzeit nicht möglich durch Sichtschatten auf der Stahlstruktur, die sich durch den Sicherheitsabstand des UAS ergeben. Insgesamt zeigt sich, dass eine Bauwerksbegutachtung mittels vorheriger Voxelisierung bzw. Rasterung zielführend ist, einen Prüfingenieur zum jetzigen Zeitpunkt jedoch keineswegs ersetzt, sondern seine Arbeit unterstützt.

## 6 Zusammenfassung und Ausblick

Es wurde ein System zur Inspektion einfacher stahlbaulicher Strukturen vorgestellt. Die Analyse befliegbarer Be-

reiche hat gezeigt, dass die drohnenunterstützte Bauwerksinspektion sehr gut genutzt werden kann, um laufende Beobachtungen oder Prüfungen eines Hallengebäudes einfacher, häufiger und genauer zu gestalten. Dank der damit weniger aufwendigen Durchführung der Inspektion werden Bauherren künftig ihre Bauwerke häufiger bzw. überhaupt überprüfen lassen, was zur Sicherheit und zu einer Verlängerung der Lebensdauer der Konstruktionen führen wird.

Insgesamt wurden die Untersuchungen auf wesentliche Schäden und gut sichtbare Schadenstellen beschränkt. Weitere Arbeiten sind z. B. im Bereich der Inspektion enger Bereiche und der Risserkennung in Schweißnähten vorstellbar. Die einzelnen Systemkomponenten wie Routenplanung, Indoor-Positionsbestimmung und Schadenserkenntnis wurden unabhängig voneinander entwickelt und können entsprechend ohne großen Aufwand für andere Systeme adaptiert oder optimiert werden. Werden beispielsweise statt Einzelbildern Videoaufnahmen der Befliegung verwendet, kann eine weitere Verbesserung der Schadenserkenntnis durch die zusammenhängende Betrachtung aufeinanderfolgender Einzelbilder erwartet werden. Zukünftig gilt es, die einzelnen Komponenten sowie Schnittstellen zu optimieren und das Gesamtsystem zu verifizieren.

Zusätzliche Erweiterungen sind durch automatische Erkennung relevanter Schadensbereiche mit Hilfe selbstlernender Verfahren und die darauf basierende Routenplanung sowie die Rückführung der ermittelten Schadensposition in ein 3D-Modell sowie die Verknüpfung mit Konstruktionsmodellen (z. B. BIM-as-built) theoretisch möglich. Damit kann die Inspektion in den Lebenszyklus des Bauwerkes integriert werden. Ebenfalls ist die Verwendung anderer Sensoren (z. B. akustischer Sensoren) zur Inspektion denkbar.

## Literatur

- Aliyari, M., Drogue, E. L., Ayele, Y.Z. (2021): UAV-Based Bridge Inspection via Transfer Learning. In: Sustainability, Jg. 13, Heft 20. DOI: 10.3390/su132011359.
- Ayoub, N., Schneider-Kamp, P. (2021): Real-Time On-Board Deep Learning Fault Detection for Autonomous UAV Inspections. In: Electronics, Jg. 10, Heft 9. DOI: 10.3390/electronics10091091.
- Azimi, M., Eslamlou, A. D., Pelican, G. (2020): Data-Driven Structural Health Monitoring and Damage Detection through Deep Learning: State-of-the-Art Review. In: Sensors, Jg. 20, Heft 10. DOI: 10.3390/s20102778.
- Bauministerkonferenz (2006): Hinweise für die Überprüfung der Standsicherheit von baulichen Anlagen durch den Eigentümer/Verfügberechtigten. Ger. Fassung September 2006. Berlin: Geschäftsstelle Bauministerkonferenz, 1.
- Besl, P., McKay, H. (1992): A method for registration of 3-D shapes. IEEE Trans Pattern Anal Mach Intell. In: IEEE Transactions on Pattern Analysis and Machine Intelligence, Jg. 14, Heft 2, 239–256. DOI: 10.1109/34.121791.
- Caballero, F., Merino, L. (2021): DLL: Direct LIDAR Localization. A map-based localization approach for aerial robots. In: 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 5491–5498. DOI: 10.1109/IROS51168.2021.9636501.

- Cha, Y.-J., Choi, W., Suh, G., Mahmoudkhani, S., Büyüköztürk, O. (2018): Autonomous Structural Visual Inspection Using Region-Based Deep Learning for Detecting Multiple Damage Types. In: Computer-Aided Civil and Infrastructure Engineering, Jg. 33, Heft 9, 731–747. DOI: 10.1111/mice.12334.
- DB Netz AG (2008): DB Richtlinie 804, Modul 8001: Eisenbahnbrücken (und sonstige Ingenieurbauwerke) planen, bauen und instand halten – Inspektion von Ingenieurbauwerken – Begriffe. DB Netz AG.
- Deutsches Institut für Normung e. V. (1999a): DIN 1076: Ingenieurbauwerke im Zuge von Straßen und Wegen – Überwachung und Prüfung. Beuth Verlag.
- Deutsches Institut für Normung e. V. (1999b): DIN EN ISO 9283: Industrieroboter – Leistungskenngrößen und zugehörige Prüfmethoden. Beuth Verlag.
- Dhiraj, Agarwal, A., Agrawal, A., Meruane, V., Sangwan, K. (2021): Development of a Machine Learning based model for Damage Detection, Localization and Quantification to extend Structure Life. In: Procedia CIRP, Jg. 98. The 28th CIRP Conference on Life Cycle Engineering, March 10–12, 2021, Jaipur, India, 199–204. DOI: 10.1016/j.procir.2021.01.030.
- Dittmar, V. (2016): Drohnen sollen Schäden an Brücken aufzeigen. [www.nordbayern.de/region/fuerth/drohnen-sollen-schaden-an-bruecken-aufzeigen-1.4976440](http://www.nordbayern.de/region/fuerth/drohnen-sollen-schaden-an-bruecken-aufzeigen-1.4976440), letzter Zugriff 25.05.2023.
- Doshi, K., Yilmaz, Y. (2020): Road Damage Detection using Deep Ensemble Learning. In: 2020 IEEE International Conference on Big Data (Big Data), 5540–5544. DOI: 10.1109/BigData50022.2020.9377774.
- Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., Zisserman, A. (2010): The Pascal Visual Object Classes (VOC) Challenge. In: International Journal of Computer Vision, Jg. 88, Heft 2, 303–338.
- Gierschner, F. (2021): Beitrag zur sensorgestützten Positionsbestimmung und Navigation autonomer Roboter. Dissertation, Universität Rostock.
- Gierschner, F., Peters, A., Harweg, T., Ambrosat, T., Weichert, F., Ungermaann, U., Flügge, W. (2021): Schlussbericht FOSTA P1326: Inspektion, Überwachung und Dokumentation von stahlbaulichen Strukturen. FOSTA – Forschungsvereinigung Stahlanwendung e. V.
- Greenwood, W. W., Lynch, J. P., Zekkos, D. (2019): Applications of UAVs in Civil Infrastructure. In: Journal of Infrastructure Systems, Jg. 25, Heft 2, 04019002.
- Haardt, P. (1997): Erarbeitung von Kriterien zur Zustandserfassung und Schadensbeurteilung von Brücken- und Ingenieurbauwerken. Bergisch Gladbach: Bundesanstalt für Straßenwesen.
- Harweg, T., Peters, A., Bachmann, D., Weichert, F. (2020): CNN-Based Deep Architecture for Health Monitoring of Civil and Industrial Structures Using UAVs. In: Proceedings, Jg. 42, Heft 1. DOI: 10.3390/ecsa-6-06640.
- He, K., Gkioxari, G., Dollár, P., Girshick, R. (2017): Mask R-CNN. In: Proceedings of the International Conference on Computer Vision (ICCV).
- He, K., Zhang, X., Ren, S., Sun, J. (2016): Deep Residual Learning for Image Recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- Jiao, L., Zhao, J. (2019): A Survey on the New Generation of Deep Learning in Image Processing. In: IEEE Access, Jg. 7, 172231–172263. DOI: 10.1109/ACCESS.2019.2956508.
- Kim, B., Yuvaraj, N., Park, H. W., Preethaa, K. S., Pandian, R. A., Lee, D.-E. (2021): Investigation of steel frame damage based on computer vision and deep learning. In: Automation in Construction, Jg. 132, 103941. DOI: 10.1016/j.autcon.2021.103941.
- Kim, B., Cho, S. (2020): Automated Multiple Concrete Damage Detection Using Instance Segmentation Deep Learning Model. In: Applied Sciences, Jg. 10, Heft 22. DOI: 10.3390/app10228008.
- Kung, R.-Y., Pan, N.-H., Wang, C. C. N., Lee, P.-C. (2021): Application of Deep Learning and Unmanned Aerial Vehicle on Building Maintenance. In: Yi, W. (Ed.): Advances in Civil Engineering, Jg. 2021, 5598690.
- Lin, T., Dollár, P., Girshick, R., He, K., Hariharan, B., Belongie, S. (2017): Feature Pyramid Networks for Object Detection. In: 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 936–944. DOI: 10.1109/CVPR.2017.106.
- Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollar, P., Zitnick, L. (2014): Microsoft COCO: Common Objects in Context. In: ECCV. European Conference on Computer Vision.
- Maghazei, O., Netland, T. H. (2019): Drones in manufacturing: exploring opportunities for research and practice. In: Journal of Manufacturing Technology Management.
- Mainblades (2021): Drone as a tool. <https://mainblades.com/drone-as-a-tool-2/>, letzter Zugriff 01.11.2021.
- Melville, J., Alguri, K. S., Deemer, C., Harley, J. B. (2018): Structural damage detection using deep learning of ultrasonic guided waves. In: AIP Conference Proceedings, Jg. 1949, Heft 1, 230004. DOI: 10.1063/1.5031651.
- Niemeyer, F. (2014). Konzept und prototypische Umsetzung eines »Four Vision«-Kamerasystems mit Anwendungen in kommunalen und landwirtschaftlichen Bereichen für den Einsatz auf UAVs (Unmanned Aerial Vehicle). Dissertation, Universität Rostock.
- O'Mahony, N., Campbell, S., Carvalho, A., Harapanahalli, S., Hernandez, G. V., Krpalkova, L., Riordan, D., Walsh, J. (2020): Deep Learning vs. Traditional Computer Vision. In: Arai, K., Kapoor, S. (Eds.): Cham Advances in Computer Vision. Springer International Publishing, 128–144.
- Perez-Grau, F. J., Caballero, F., Viguria, A., Ollero, A. (2017): Multi-sensor three-dimensional Monte Carlo localization for long-term aerial robot navigation. In: International Journal of Advanced Robotic Systems, Jg. 14, Heft 5. DOI: 10.1177/1729881417732757.
- Rastin, Z., Ghodrati Amiri, G., Darvishan, E. (2021): Unsupervised Structural Damage Detection Technique Based on a Deep Convolutional Autoencoder. In: Cademi, S. (Ed.): Shock and Vibration, Jg. 2021, 6658575.
- Schöning, U. (2011): Algorithmik. Spektrum Akademischer Verlag.
- Schwandt, T. (2017): Schiffspropeller-Hersteller MMG setzt auf Industrieroboter. <https://industrieanzeiger.industrie.de/allgemein/schiffs-propeller-hersteller-mmg-setzt-auf-industrieroboter/>, letzter Zugriff 01.11.2021.
- Shan, T., Englot, B., Meyers, D., Wang, W., Ratti, C., Rus, D. (2020): LIO-SAM: Tightly-coupled Lidar Inertial Odometry via Smoothing and Mapping. In: 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 5135–5142. DOI: 10.1109/IROS45743.2020.9341176.
- Shanthakumar, P., Yu, K., Singh, M., Orevillo, J., Bianchi, E., Hebdon, M., Tokekar, P. (2020): View Planning and Navigation Algorithms for Autonomous Bridge Inspection with UAVs. In: Xiao, J., Kröger, T., Khatib, O. Cham (Eds.): Proceedings of the 2018 International Symposium on Experimental Robotics. Springer International Publishing, 201–210.
- Shorten, C., Khoshgoftaar, T. M. (2019): A survey on Image Data Augmentation for Deep Learning. In: Journal of Big Data, Jg. 6, Heft 1, 60.
- Singh, Priyanka, Ahmad, Umaid Faraz, Yadav, Siddharth (2020): Structural Health Monitoring and Damage Detection through Machine Learning approaches. In: E3S Web Conf., Jg. 220, 01096. DOI: 10.1051/e3sconf/202022001096.
- Soille, P. (2003): Morphological Image Analysis: Principles and Applications. 2nd Edition. Secaucus, NJ: Springer-Verlag, 219–221.
- Sony Europe B. V. (o. D.): ILCE-6000 / ILCE-6000L / ILCE-6000Y / ILCE-6000Z Technische Daten | Kameras mit Wechselobjektiv | Sony DE. [www.sony.de/electronics/wechselobjektivkameras/ilce-6000-body-kit/specifications](http://www.sony.de/electronics/wechselobjektivkameras/ilce-6000-body-kit/specifications), letzter Zugriff 21.09.2021.
- Sperber, Gößmann (2016): Unterstützung der Bauwerksprüfung durch innovative digitale Bildauswertung – Pilotstudie. In: BASt – Forschungsbericht Nr. 15.0602/2014/LRB.
- Torrey, L., Shaylik, J. (2010): Transfer Learning. In: Olivas, E. S., Guererro, J. D. M., Martinez-Sober, M., Magdalena-Benedito, J. R., Serrano López, A. J., Hershey, PA, USA (Eds.): IGI Global, 242–264.
- Verein Deutscher Ingenieure e. V. (2010): VDI 6200: Standsicherheit von Bauwerken.
- Wang, N., Zhao, Q., Li, S., Zhao, X., Zhao, P. (2018): Damage Classification for Masonry Historic Structures Using Convolutional Neural Networks Based on Still Images. In: Computer-Aided Civil and Infrastructure Engineering, Jg. 33, Heft 12, 1073–1089. DOI: 10.1111/mice.12411.

- Weinzierl, S. (2020): Industrie-Inspektion mit Drohnen: Heulen im Kamin. [www.instandhaltung.de/praxisanwendung/industrie-inspektion-mit-drohnen-heulen-im-kamin-221.html](http://www.instandhaltung.de/praxisanwendung/industrie-inspektion-mit-drohnen-heulen-im-kamin-221.html), letzter Zugriff 01.11.2022.
- Won, J., Park, J.-W., Jang, S., Jin, K., Kim, Y. (2021): Automated Structural Damage Identification Using Data Normalization and 1-Dimensional Convolutional Neural Network. In: Applied Sciences, Jg. 11, Heft 6. DOI: 10.3390/app11062610.
- WPM Ingenieure (2001): Erstellung Software SIB Bauwerke. Neunkirchen-Heinitz: Ingenieurgesellschaft für Bauwesen und Datenverarbeitung mbH.
- Wu, Y., Kirillov, A., Massa, F., Lo, W.-Y., Girshick, R. (2019): Detectron2. <https://github.com/facebookresearch/detectron2>, letzter Zugriff 27.10.2021.
- Yosinski, J., Clune, J., Bengio, Y., Lipson, H. (2014): How Transferable Are Features in Deep Neural Networks? In: Proceedings of the 27th International Conference on Neural Information Processing Systems, Volume 2. NIPS'14. Montreal, Canada: MIT Press, 3320–3328.
- Zhang, D., Watson, R., Dobie, G., Macleod, C., Pierce, G. (2018): Autonomous Ultrasonic Inspection Using Unmanned Aerial Vehicle. In: 2018 IEEE International Ultrasonics Symposium (IUS). IEEE, 1–4. DOI: 10.1109/ULTSYM.2018.8579727.

**Kontakt**

Tina Ambrosat | Fabian Gierschner  
Fraunhofer IGP  
Albert-Einstein-Straße 30, 18059 Rostock  
tina.ambrosat@igp.fraunhofer.de | fabian.gierschner@tuta.io

Annika Hundrup | Dieter Ungermaann  
Technische Universität Dortmund, Lehrstuhl Stahlbau  
August-Schmidt-Straße 6, 44227 Dortmund  
annika.hundrup@tu-dortmund.de | dieter.ungermann@tu-dortmund.de

Thomas Harweg | Frank Weichert  
Technische Universität Dortmund, Informatik VII  
Otto-Hahn-Str. 16, Raum 101, 44227 Dortmund  
thomas.harweg@tu-dortmund.de | frank.weichert@tu-dortmund.de

Wilko Flügge  
Universität Rostock, Lehrstuhl Fertigungstechnik  
Fraunhofer IGP  
Albert-Einstein-Straße 30, 18059 Rostock  
wilko.fluegge@uni-rostock.de

Dieser Beitrag ist auch digital verfügbar unter [www.geodaesie.info](http://www.geodaesie.info).