

Abschlussbericht

Zuwendungsempfänger: Fraunhofer-Gesellschaft zur Förderung der angewandten Forschung e.V. ausführende Stelle: Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA	FKZ: 13N14840
Verbundprojekt: Inspection and visualization of vehicles in motion based on Optical 3D-Metrology and Embedded Vision for an innovative fleet monitoring and turnaround management (INVIVO) Teilvorhaben: Algorithmen für die Inspektion und Messung großer Objekte in Bewegung	
Teilprojektleitung: Dr.-Ing. Ira Effenberger	
Autoren: M. Sc. Manuel Kaufmann, Dipl.-Math. Andreas Frommknecht, Dr.-Ing. Ira Effenberger	
Laufzeit des Vorhabens: von: 1.5.2018 bis: 31.12.2020	

I. Kurzbericht

Aufgabenstellung

Schäden an Leih- und Flottenfahrzeugen führen zu einem signifikanten finanziellen Schaden bei den Fahrzeugeigentümern. Selbst kleine Beschädigungen z.B. bei Leihfahrzeugen, Kleintransporten (z.B. von Paketdiensten) oder öffentlichen Nahverkehrsbussen stellen aufgrund ihrer großen Anzahl Verluste im Bereich von mehreren Millionen dar. Bei Fahrzeugverleihen ist die Schadensaufnahme äußerst personalintensiv, nicht ausreichend objektiv und oft mit Diskussionen mit dem Kunden verbunden. Eine größere Objektivierung würde hier zu einer deutlich verbesserten Geschäftsbeziehung der verschiedenen Marktteilnehmer führen. Erste Experimente mit Pilotsystemen, die eine objektive Standarddokumentation liefern, zeigen sowohl eine Reduktion der Kosten als auch eine deutlich bessere Kundenakzeptanz bei der Schadensaufnahme. Seit vielen Jahren verlangt der Markt hier nach einer zufriedenstellenden Lösung für die aufgezeigten Probleme.

In den letzten Jahren hat das Interesse an 3D-Applikationen im Bereich der Inspektion und Messtechnik stark zugenommen. Dabei wird die Entwicklung von neuen Applikationen massiv unterstützt durch leistungsfähigere und kostengünstige Hardwareplattformen, vielfältige Sensortechnologie zur schnellen 3D-Datenaufnahme sowie leistungsstarke Algorithmen zur effizienten Verarbeitung und automatisierten Auswertung der 3D-Daten. Aufbauend auf diesen Technologien und Verfahren war das Ziel des Verbundvorhabens INVIVO die automatisierte Inspektion von Fahrzeugen in Bewegung auf Basis von geeigneter optischer Sensorik und Embedded-Vision-Technologie, um ein innovatives Flottenmanagement sowie Turnaround-Management bei Mietwagenfirmen und ihren Dienstleistern zu ermöglichen. Unter Turnaround-Management wird hierbei das Management aller Dienstleistungen von der Fahrzeugrückgabe über die Schadensdokumentation und Wartung bis hin zur Wiederbereitstellung der Fahrzeuge für den nächsten Kunden verstanden.

Ablauf des Vorhabens

Das Vorhaben wurde nach dem in der Vorhabenbeschreibung festgelegten Arbeitsplan durchgeführt. Zunächst wurden relevante Anwendungsfälle ausgewählt, die ein breites Spektrum an Anforderungen für das objektive Verfolgen von Zeitpunkt, Position und Ausmaß von Fahrzeugbeschädigungen liefern. Die weiteren Arbeitsschwerpunkte im Verbundprojekt lagen dann auf der Erforschung eines 3D-Smartsensors mit integrierter Datenauswertung, der Entwicklung einer geeigneten 3D-Datenverarbeitung für die Visualisierung und die intelligente Geometrie- und Oberflächeninspektion, dem Design und Aufbau eines Demonstrators zur multimodalen Datenaufnahme von kompletten Fahrzeugen in Bewegung sowie der Entwicklung einer geeigneten graphischen Bedienerschnittstelle (GUI) mit Cloud Anbindung, um Inspektionsergebnisse und Bedienereingaben an unterschiedlichen Standorten (z.B. Mietwagenstationen) zugänglich zu machen.

Das Teilvorhaben des Fraunhofer IPA zielte auf die Erforschung und Entwicklung von Algorithmen für die Inspektion von Fahrzeugen in Bewegung ab. Hierbei war die Untersuchung von Verfahren zur robusten und schnellen 3D-Datenverarbeitung von Punktwolken zur Formüberwachung und Inspektion großer Objekte im Hinblick auf das Anwendungsszenario Flottenmanagement und Fahrzeugverleih ein wesentlicher Bestandteil. Der Fahrzeugscanner bewegt sich bei der Datenaufnahme mit konstanter Geschwindigkeit, um die Oberfläche des Fahrzeugs hochaufgelöst zu erfassen. Dabei werden sowohl 3D-Messdaten in Form von Punktwolken als auch Bilddaten erfasst. In den Messdaten sollte die Erkennung von Oberflächenbeschädigungen wie Dellen ermöglicht werden, die aufgenommenen 2D-Bilddaten werden vor allem für die Detektion von Kratzern herangezogen.

Wesentliche Ergebnisse

Zunächst wurden mit verschiedenen deutschen und griechischen Anwendern aus der Mietwagen- und Fleetmanagement-Branche die zu erkennenden, relevanten Defekte und Defektgrößen diskutiert und auf dieser Basis die detaillierten Anforderungen an den Fahrzeugscanner festgelegt, insbesondere an die optische Sensorik zur Datenerfassung sowie an die Inspektionsverfahren zur Auswertung der Bild- und 3D-Messdaten vom Fahrzeug.

Der vom Projektpartner EVT entwickelte 3D-Sensor wurde in einen Laboraufbau am Fraunhofer IPA integriert und in Betrieb genommen. Anschließend wurden Testreihen zur Datenaufnahme anhand von verschiedenen lackierten Blechen und Fahrzeugteilen durchgeführt, um einerseits optimale Parametereinstellungen für die Datenaufnahme zu ermitteln und andererseits die erzielbare Datenqualität und Datendichte hinsichtlich der zu erfüllenden Anforderungen zu bewerten.

Der Schwerpunkt der Forschungsarbeiten des Fraunhofer IPA lag auf der Untersuchung und Entwicklung von Verfahren zur Auswertung der Bild- und Sensordaten, um Defekte am Fahrzeug zuverlässig zu erkennen. Hierbei wurden sowohl lokale Verfahren zur 3D-Datenauswertung in Punktwolken analysiert als auch Verfahren, die einen 3D-Vergleich des Fahrzeugs vor und nach der Nutzung ermöglichen, jedoch sehr rechenintensiv sind. Darüber hinaus wurde im Laufe des Projekts verstärkt auf maschinelle Lernverfahren gesetzt, um Defekte anhand der Bilddaten vom Fahrzeug zu erkennen und einer Fehlerklasse zuzuordnen. Es wurden unterschiedliche Deep-Learning-Ansätze untersucht und schließlich ein stufenweises Verfahren gewählt, das zunächst das Fahrzeug vom Hintergrund unterscheidet und dann die Defektbereiche am Fahrzeug identifiziert. Hier konnten bereits mit einer recht geringen Anzahl an Trainingsdaten vielversprechende Ergebnisse erzielt werden, die nach Projektende weiterverfolgt und erweitert werden. So konnten verschiedene Klassen von Defekten unterschieden werden wie z.B. Kratzer, Dellen, Verformungen oder Felgenschäden und selbst kleine Kratzer erkannt werden.

II. Wissenschaftlich-technische Ergebnisse

Nachfolgend sind die gemäß Arbeitsplan durchgeführten Arbeiten und die im Projekt erzielten wissenschaftlich-technischen Ergebnisse beschrieben.

AP1: Anforderungsanalyse des Fahrzeugverleihs und des Flotten Managements:

Ziel des Arbeitspakets 1 ist die Darstellung der Anforderungen des Markts an ein optisches 3D-Fahrzeuginspektionssystem durch eine Anforderungsliste. Parallel wurden in den einzelnen Anwendungsgebieten Befragungen von Interessenten durchgeführt und diese mit bestehenden Scanner-Systemen abgeglichen, um so eine den Kundenanforderungen gerecht werdende, aber auch marktrelevante Lösung zu erhalten. Die Kundenanforderungen wurden mittels der Methode des „House of Quality“ in Produktanforderungen „übersetzt“.

Die Ermittlung der Anforderungen der einzelnen potentiellen Branchen (siehe Abb. 1) und deren Clustering erfolgten parallel zur Nutzerbefragung und Recherche.




Abbildung 1: potentielle Branchen

Die Branchen lassen sich zu anforderungsspezifischen Clustern zusammenfassen. Die Vielzahl der Anwendungen lässt sich in drei Fälle, Mietwagen-Check, Hagelschaden-Check und Wiederverkauf unterteilen, die sich in zeitlichen, räumlichen und leistungsbedingten Aspekten unterscheiden (siehe Abb. 2). Die folgenden Befragungen wurden entsprechend dieser Aufteilung durchgeführt und Anforderungen des Demonstrators ebenso bezüglich dieses Schemas abgeleitet.

Im Folgenden werden die anwendungsspezifischen Anforderungen beschrieben, die durch Anfragen und Literaturrecherchen ermittelt wurden.

Use Cases mit Versicherern

In einer ersten Recherche zu Schadensfällen, die an Fahrzeugen auftreten, wurden über die Analyse von Versicherungsstatistiken potentiell hohe Schadenssummen bei Naturereignissen, vornehmlich Hagel, ausgemacht. Beispielsweise verursachte ein Hagelsturm am 31.05.2018 in der Schweiz rund 17,2 Millionen Euro Schaden an Fahrzeugen zur Kompensation durch die Versicherer. Ca. 10 % der eingereichten Versicherungsabrechnungen seien laut Focus1 Versicherungsbetrugsfälle, was bei rund 24 Millionen Versicherungsfällen einer Summe von 2,4 Betrugsfällen und einer Schadenssumme

¹ Quelle: https://www.focus.de/finanzen/versicherungen/jeder-zehnte-fall-ist-gar-keiner-deutsche-betruegen-ihre-versicherungen-wo-sie-nur-koennen-und_id_5246090.html

von rund 4 Milliarden Euro pro Jahr in Deutschland entspricht. Angesichts dieser Zahlen und der hohen Summen stellt ein Scanner ein Mittel zur Objektivierung der Schadensregulation dar.

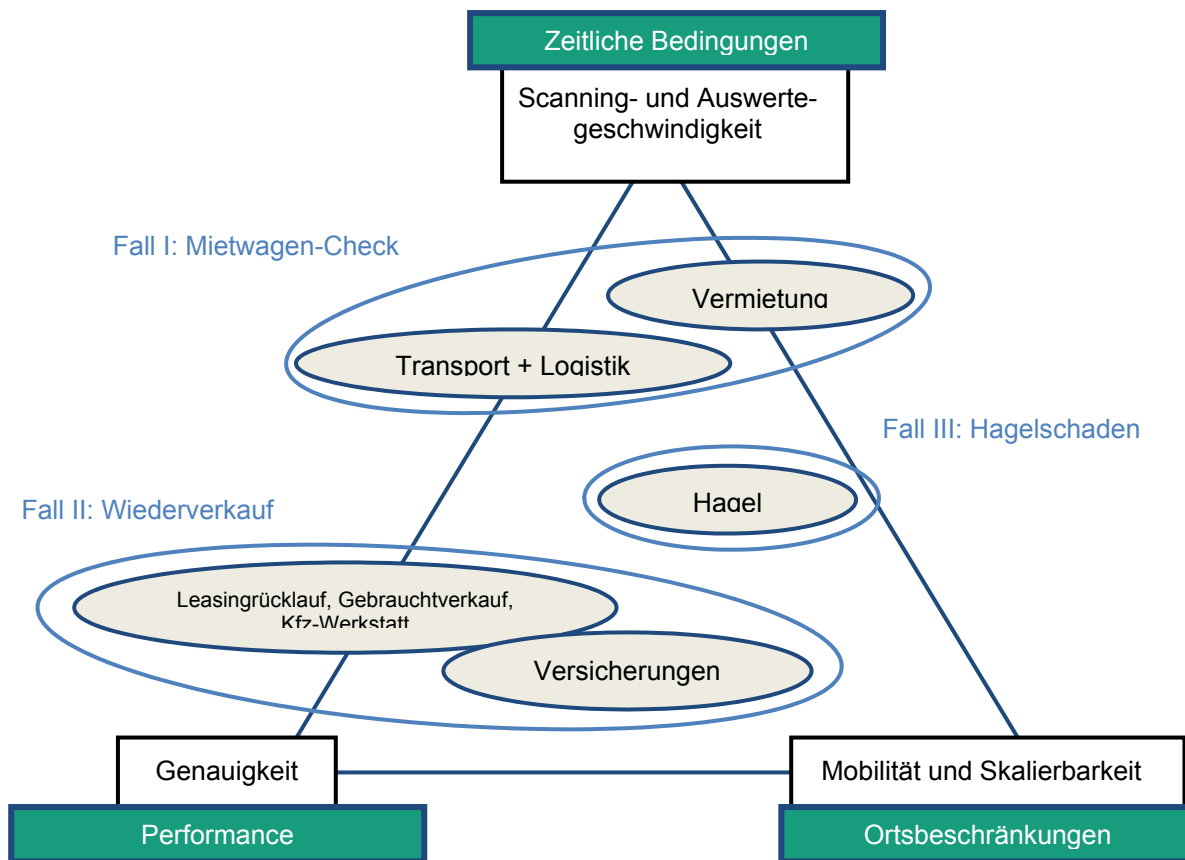


Abbildung 2: Clustering der Anwendungsfälle

Anwendungen im Flottenmanagement

Der Transport von Gütern in der Logistik auf der sogenannten „letzten Meile“ nimmt in Deutschland immer weiter zu. So werden laut Statista rund 70 % der Umsätze von Logistikern auf der Straße generiert. Durch zunehmende Transporte und die damit verbundene Arbeitsverdichtung steigt die Wahrscheinlichkeit für Schäden an den Transportern. Bei der Firma Blitz Kurier in Essen spiegelt sich dies in einer Schadenssumme von ca. 200.000 € bei 100 Kleintransportern im Zeitraum vom Januar bis April 2018 wider, was einem durchschnittlichen Schaden von 2.000 € pro Transporter in diesen vier Monaten entspricht, die aufgrund hoher Versicherungsprämien unwirtschaftlich zu versichern wären².

Durch die Implementierung eines reinen Dokumentationssystems, eines Tunnels mit Kameras zur Erzeugung von Fotos zur Repräsentation der aktuellen Fahrzeugschäden, konnte bei der Firma Blitz Kurier die Anzahl der neu auftretenden Schäden deutlich reduziert werden. Durch diesen psychologischen Mechanismus der Kontrolle des Fahrers vor und nach dem Einsatz allein lässt sich

² Quelle: RP-online.de

im Pilotprojekt bei Blitz Kurier die Wirksamkeit der Schadensdokumentation bei Fahrzeugen im Flottenmanagement zeigen. Fahrer, die sich für ihr Fahrzeug verantwortlich fühlen, gehen damit sorgsamer um, so die daraus abgeleitete These.

Anforderungsermittlung bei Leasing-Rückläufern

Die potentiell auftretenden Schäden wurden einer Internetrecherche, aber auch Richtlinien von Flottenbetreibern zur Rücknahme gebrauchter Fahrzeuge entnommen. Darunter sind beispielsweise der „Fair return-Guide“ der DEKRA mit einer transparenten und möglichst vollständigen Fehlerbeschreibung zu nennen, der sich als Quasi-Standard im Leasing-Bereich etablieren möchte bzw. schon etablierte und frei im Internet auf der DEKRA-Homepage zu finden ist. Weitere „Fair tear and wear“-Guides lehnen sich teilweise an die Empfehlungen der DEKRA an.

Eine Besprechung mit Vertretern der Emil Frey Gruppe in Stuttgart ergab eine Einsicht in die Anforderungen dieses großen Leasing-Management-Unternehmens. Ein besonderes Augenmerk legen die Entscheider dort auf kurze Inspektionszyklen, damit hohe Kapazitäten erzielt werden, mit der Aussicht auf einen möglichst wirtschaftlichen Betrieb. Bei min. 20 Fahrzeugen pro Tag und 5000 Fahrzeugen pro Jahr wäre eine Wirtschaftlichkeit bei überschlägigen 50.000 € Investitionskosten gegeben. Neben den beschriebenen Defektklassen wäre eine Erkennung einer Schadenskorrektur durch eine Lackdickenmessung wünschenswert. Ein selbstfahrender Betrieb, indem der Kunde selbst durch ein Messsystem fährt, wird aufgrund der Erfahrungen mit zahlreichen Beschädigungen mit Waschanlagen-Systemen ausgeschlossen. Dennoch werden Transport-Systeme wie Schleppketten kritisch gesehen, da diese laut Aussage rund 30.000 € bis 50.000 € Instandhaltungskosten pro Jahr verursachen. Ein Scan-as-a-Service-Modell wäre attraktiv, wobei ein Verbleiben der Daten beim Dienstleister wünschenswert wäre, um Kosten für die Datenvorhaltung zu sparen. Eine Nutzung der 3D-Visualisierung der generierten Daten für Marketingzwecke, z.B. zum Online-Gebrauchtwagenverkauf, wäre erstrebenswert.

Ein weiteres Treffen, mit der DEKRA Stuttgart als Vertreter der Gutachter, zeigt die Möglichkeiten in der Digitalisierung der Schadensregulierung bei Versicherern auf. Ein selbst zu bedienender Scanner, der im Schadensfall angefahren wird und über den die Schadenshöhe kalkuliert wird, wäre ein möglicher Baustein in der Digitalisierungsstrategie von Versicherungen, um Kosten für Kfz-Gutachten zu minimieren. Durch umfangreiche Benchmark-Maßnahmen der DEKRA zeigt sich, dass alle auf dem Markt verfügbaren Systeme aktuell „eine offene Flanke“, also fehlende Funktionen haben. Bei allen Überlegungen wird angenommen, dass die Detektionsrate des Systems höher ist als die des Menschen. Im Gegenteil zur Emil Frey Gruppe würde die DEKRA eine vollständige Hoheit über Daten und Assets anstreben. Eine Scanzeit, genauso wie die anschließende Auswertzeit dürfte 30 Sekunden nicht überschreiten, um die Integration in bestehende Prozesse bei der Gutachtung nicht zu gefährden. Als Zielgröße werden ebenso Investitionskosten von 50.000 € angegeben.

Anforderungsermittlung bei Autovermietern

Im Rahmen des Projekts wurden Richtlinien der Autovermieter AVIS und Sixt eingeholt. Bei Anfrage weiterer Vermieter wie Europcar, Hertz und der Enterprise-Gruppe konnten mündlich oder frei formulierte Kriterien ermittelt werden. Zugleich wurden die angesprochenen Vermieter bezüglich des Prozesses der Schadensermittlung und –regulierung befragt. Hierzu wurde ein im Konsortium entwickelter Fragebogen ausgegeben. Dieser Fragebogen, welcher an deutsche Fahrzeugvermieter wie auch griechische Vermietstationen verteilt wurde, beinhaltet folgende thematische Aspekte:

Prozess-Assessment: Wie wird aktuell die Schadenserfassung betrieben? Wie sind die zeitlichen Restriktionen, potentielle Fehlerraten, Öffnungszeiten der Rücknahme, Kapazitäten in Fahrzeugen pro Tag und die Kundenakzeptanz des Prozesses?

Rückmeldung: Defekte werden meist manuell in Papierform in Schemata eingetragen, wodurch ein gesamter Inspektionsprozess ca. 2 bis 5 Minuten dauert. Meist werden die Fahrzeuge davor gereinigt, um Defekte von Verschmutzungen besser unterscheiden zu können. Die Annahmestationen sind meist rund um die Uhr geöffnet und es werden Kapazitäten von 5 bis über 100 Fahrzeuge pro Tag bearbeitet. Mehr als ein Drittel der Kunden beschwert sich über die ihm zugeordneten erfassten Schäden, auch bei vorhandener Rechtfertigung und Prozesstransparenz.

Technische Aspekte: Welche Schäden treten wie häufig auf? Wie hoch sind die Schadenskosten? Wie wären, bei Einsatz eines Scanners, die größtmöglichen räumlichen Abmessungen eines Scannersystems?

Rückmeldung: Hauptsächlich treten Schäden wie Kratzer und Dellen auf. Diese sind häufig an der Unterseite von Fahrzeugen zu finden. Am häufigsten sind Kratzer an Schweller und Frontschürze. Ebenso häufig treten Dellen im Türbereich auf. Die Kosten liegen bei ca. 100 € im Durchschnitt pro Kratzer in Griechenland, bei Dellen deutlich höher. Kosten in Deutschland sind ebenso höher zu bewerten. Weitere häufige Defekttypen sind gebrochene Spiegelgläser sowie der Austausch von Fahrzeugkomponenten wie z.B. der Räder gegen weniger wertige Austauschräder. Laut Vermietern dürfte ein Scannersystem ungefähr den Raum einer Waschanlage, bei manchen Kunden nur den Platz zweier Parkplätze einnehmen.

Kundenbeziehung und wirtschaftliche Verwertung: Wie häufig beschweren sich Kunden über erkannte Schäden? Würde ein Scanner zu mehr Transparenz in der Kundenbeziehung führen? Würden Sie (aus Transparenzgründen) in einen Scanner investieren und falls ja, wie teuer dürfte dieser sein?

Rückmeldung: Kunden beschweren sich in ca. 1/3 der Fälle über die entdeckten Schäden. Daher erwarten die Vermieter, dass durch einen Scanner die Transparenz erhöht wird und somit die Kundenakzeptanz, auch gegenüber nicht erfassten Schäden vom Vormieter, erhöht wird. Die meisten Befragten würden in ein System investieren. In Griechenland liegt die Investitionssumme

bei 1000 bis 3000 € sehr niedrig, Investoren in Deutschland würden 25.000 bis 50.000 € ausgeben und stellen damit einen „komfortableren“ Budgetrahmen dar.

Rückgabe-Richtlinien der Vermieter wie z.B. AVIS klassifizieren in Kratzer und Dellen sowie Steinschläge. Bei AVIS sind branchenüblich Kratzer bis 2,5 cm Länge, wenn keine Farbe entfernt ist, sowie Dellen bis 2,5 cm Durchmesser, ebenso nur ohne Farbverlust, sowie Steinschläge bis 3 mm Durchmesser zulässig. Bei Farbverlust ist immer ein Schadensfall eingetroffen. Somit werden folgende Kundenanforderungen für den Mietwagenfall abgeleitet:

- Dellen von min. 25 mm erfassbar
- Kratzer ab 25 mm erfassbar
- Farbabplatzer erfassbar
- Kratzer nahe des Unterbodens auf der Unterseite der Frontschürze und am Schweller erfassbar
- Steinschläge ab 3 mm Durchmesser optional erfassbar
- Anomalien wie ersetzte Teile und gebrochene Spiegel optional detektierbar

Die technischen Anforderungen entlehnen sich den beschriebenen Kundenanforderungen und wurden über das Werkzeug des „House of Quality“ in funktionale Aspekte übersetzt. In Zusammenarbeit mit dem Konsortium wurden die Anforderungen beurteilt und festgelegt. Ergebnisse der Befragungen sowie Schadenskataloge wie die „Fair Tear or Wear-Guides“ wurden herangezogen. Hervorzuheben sind eine geforderte laterale Auflösung von 2,5 mm und eine Tiefenauflösung von 0,2 mm.

Arbeitspaket 2: Design des Gesamtsystems inklusive Businesslogik

Hinsichtlich des Gesamtkonzepts für den Fahrzeugscanner und insbesondere in Bezug auf die Anordnung der Sensoren wurden sowohl vom griechischen Partner IKnowHow als auch vom Fraunhofer IPA unterschiedliche Konzepte erarbeitet, die eine schnelle und robuste Datenerfassung des Fahrzeugs ermöglichen und zudem noch möglichst flexibel einsetzbar sind. Diese Konzepte wurden mit den anderen Verbundpartnern beim Projekttreffen in Thessaloniki Anfang Oktober 2018 diskutiert und ein Gesamtkonzept für den Demonstratoraufbau verabschiedet.

Neben der 3D-Laserliniensensoren, die vom Partner EVT entwickelt werden und das Fahrzeug sowohl von oben als auch von den Seiten erfassen sollen, ist weiterhin der Einsatz von hochauflösenden Farbzeilenkameras vorgesehen, um Kratzer und Lackschäden detektieren zu können. Aufgrund der optischen Eigenschaften der Fahrzeugoberflächen und daraus resultierende Reflexionen ist die Erfassung mit Farbzeilenkameras robuster als mit Matrixkameras. Weiterhin erscheint die Registrierung der 3D-Scandaten, die in einzelnen Profilen vorliegen, mit den Farbzeilen besser realisierbar. Somit wurde eine Umsetzung mittels 3D-Laserliniensensoren und Farbzeilenkameras ebenfalls beim Konsortialtreffen Anfang Oktober 2018 festgelegt. Zur Anpassung

an variierende Szenen soll eine Helligkeitsadaption implementiert werden, wodurch die Beleuchtung für helle oder dunkle Oberflächen spezifisch eingestellt werden kann.

Die Umsetzung des kinematischen Systems als Portalbauweise mit zusätzlichem Rotationsgelenk erlaubt die Datenakquisition an Flächen unterhalb der Fahrzeuggrundlinie, z.B. im Bereich von Schweller und Frontschürze, die häufig beschädigte Teile im Bereich der Fahrzeugvermietung darstellen. Das in einem Tunnel positionierte Fahrzeug wird unter Abwesenheit von Personen gescannt, indem sich das Portal entlang des Fahrzeugs bewegt und zugleich der Querbalken in der Höhe entlang der Fahrzeugkontur nachgeführt wird. Die entlang der Querbalken-Längsachse schwenkbare Sensorik dient zur Nachführung des Sensors flächennormal zur Fahrzeugkontur, beispielsweise im Bereich von Frontschürze und Heckklappe. Das Konzept des Aufbaus, ohne Tunnel, ist in Abbildung 3 ersichtlich.




Abbildung 3: Angedachtes Design des Gesamtsystems (ohne Tunnel)

Arbeitspaket 4: Multimodale Datenaufnahme

Im Labormaßstab wurden Messdaten mit Hilfe des Lasertriangulationssensors des Projektpartners EyeVision Technology (EVT) erfasst. Hierbei wurden verschiedene Bauteile erfasst, die unterschiedliche Komponenten von Fahrzeugen repräsentieren sollen. Zum einen wurden lackierte Blechbauteile mit verschiedener Geometrie, zum anderen wurden gefärbte sowie (teil-) transparente Kunststoffteile wie z.B. Scheinwerferglas als Testobjekte herangezogen. Als Messobjekte wurden ein glänzendes Miniaturauto in der Farbe Rot mit Freiformflächen, ein Automodell in der Farbe schwarz, welches halb glänzend, halb matt ist (siehe Abb. 4), diverse lackierte Blechstreifen mit und ohne Defekten (siehe Abb. 5) sowie eine Scheinwerferabdeckung analysiert (siehe Abb. 6).



Abbildung 4: Fahrzeug-Modelle mit halb matter und halb glänzender Oberfläche (links) und mit glänzender Oberfläche (rechts)




Abbildung 5: Blechproben in glänzend, matt sowie mit Defekten



Abbildung 6: Fahrzeug-Heckscheinwerferabdeckung

Ziel des Arbeitspakets zur Sensordatenaufnahme ist zum einen die Inbetriebnahme und die Datenübertragung vom Sensor zum Computer mithilfe einer geeigneten Schnittstelle, zum anderen das Parametrieren der Sensoreinstellungen bezüglich einer bestmöglichen Aufnahmequalität.

Zur Sensordatenerfassung wurde der vom Projektpartner EVT im Rahmen des Projekts entwickelte Lasertriangulationssensor genutzt. Zur Ansteuerung des Sensors wurde eine Ethernet-Schnittstelle vorgesehen, sodass der Sensor an übliche (Industrie-) PC-Systeme angeschlossen werden kann. Die Stromversorgung erfolgt gleichermaßen über Power-over-Ethernet (PoE). Um mit dem Sensor zu kommunizieren, existiert eine programmierbare Schnittstelle (API) sowie eine grafische Nutzeroberfläche in der Software EyeVision von EVT, die beide verwendet werden können. Die relative Bewegung zwischen Sensor und Messobjekt zur Erfassung der Objektoberfläche wurde mittels einer Linearachse umgesetzt, auf der der Sensor angebracht wurde. Das Messobjekt war statisch im entsprechenden Arbeitsabstand (ca. 100-150 mm) positioniert.

Zur Parametrierung bzw. Optimierung der Aufnahmequalität können die Parameter Belichtungszeit, Abtastrate, Laserleistung sowie eine Region of Interest (Auswertebereich) festgelegt werden. Anhand der Untersuchungen zeigte sich, dass die Qualität der Aufnahmen sehr stark vom Messobjekt und dessen optischen Eigenschaften abhängt. Dies führt dazu, dass Aufnahmen von Messobjekten mit variierenden optischen Eigenschaften tendenziell artefaktbehaftet sind. Monomaterial-Aufnahmen können bestmöglich eingestellt werden, sodass Artefakte hier relativ gut vermieden werden können. Für Aufnahmen von schwarzen Bauteilen muss die Laserleistung des verwendeten Sensors bis auf den Maximalwert erhöht werden. Für beispielsweise rote, glänzenden Bauteile sowie teiltransparente Kunststoffe (Scheinwerferabdeckung) wurde mit einer deutlich niedrigeren Laserleistung gearbeitet (ca. halbe Laserleistung). Vergleichsaufnahmen mit dem bereits am Fraunhofer IPA vorhandenen System „SICK Ruler“ des Herstellers SICK, einem ähnlichen Lasertriangulationssensor mit allerdings größerer Auflösung, zeigte die Vorteile des EVT-Sensors, die sich in einer geringeren Artefaktausprägung sowie der höheren Messdatenauflösung äußert. Für die Defekterkennung der Defektgrößen, wie in Arbeitspaket 1 in der Anforderungsanalyse über die zu erkennenden Schadensklassen ermittelt, ist diese höhere Auflösung notwendig. Somit können mehr Messpunkte in den Defektbereichen aufgenommen werden, was die Auswertung dieser erleichtert (siehe Abb. 7).

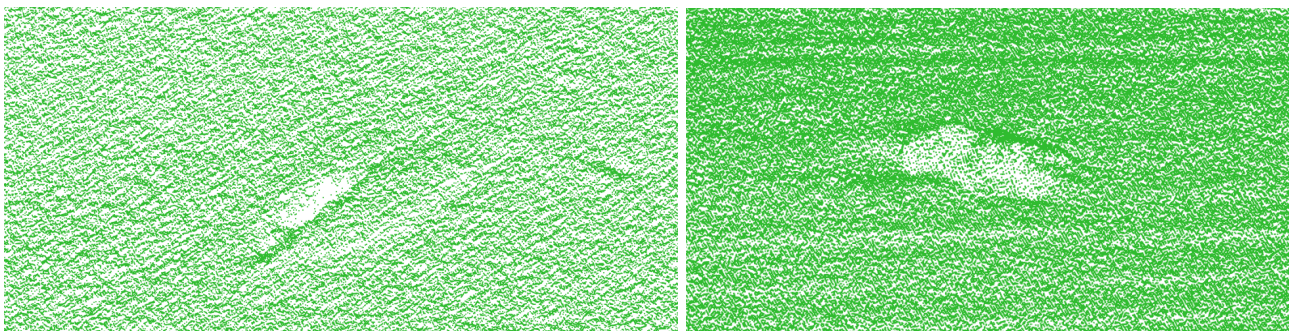


Abbildung 7: Datenerfassung auf Lackprobe mit Defekt mit SICK Sensor (links, mit fehlenden Messpunkten in der Defektzone) und mit EVT-Sensor (rechts, mit vorhandenen Messpunkten in der Defektzone)

Größere Abweichungen zum Triangulationswinkel mit mehr als ca. $\pm 20^\circ$ Neigung führen zu einem starken Anstieg der Artefakte. Dabei handelt es sich um Messpunkte, die nicht der realen Bauteil-

Geometrie entsprechen und beispielsweise durch starke Reflexion entstehen. Für glänzende Bauteile findet eine Reflexion unter großen Winkeln in den Sensor statt. Für matte, schwarze Bauteile wird kaum Laserlicht reflektiert, weshalb kein signifikantes Signal am Sensor ermittelt wird. Somit treten bei matten, schwarzen Bauteilen statt Artefakten fehlende Messpunkte auf. In Abbildung 8 sind zwei Datensätze dargestellt, für die eine unterschiedliche Artefakt-Ausprägung charakteristisch ist. Bei einer flachen Blechprobe treten keine signifikanten Artefakte auf, da der Triangulationswinkel sowie die Sensoreinstellungen beim Scannen der Oberfläche möglichst optimal gehalten werden können. Beim Miniatur-Automodell mit einer glänzenden sowie einer rauen Seite treten beide Fälle jedoch gleichzeitig auf, weshalb ein Kompromiss gefunden werden muss. Zugleich ist der Triangulationswinkel in den Flankenbereichen und in den Bereichen der Freiformflächen relativ groß, weshalb Artefakte im glänzenden Bereich sowie fehlende Messpunkte im matten Bereich resultieren.

Für die später erfolgenden Aufnahmen mit dem EVT-Sensor am Aufbau des Fahrzeugscanners konnten wertvolle Erkenntnisse gewonnen werden. Zum einen können ermittelte Parameter für die Objektklassen zukünftig genutzt werden. Zum anderen wurden die Grenzen des Messverfahrens aufgezeigt, in ihren optischen Eigenschaften stark unterschiedliche Objekte in einem Scan aufzunehmen. So können beispielsweise für den Demonstratoraufbau intelligente Verfahren zur Reduktion der Artefakte implementiert werden oder sequentielle Scanverfahren umgesetzt werden, wodurch die glänzenden Bereiche der Fahrzeuge wie der Seitenflächen mit anderen Einstellungen wie matte Bereiche, wie z.B. Anbauteile, gescannt werden.




Abbildung 8: Artefakte im Bereich von Geometrien, welche vom Triangulationswinkel abweichen. Flache, glänzende Blechprobe ohne Artefakte (links). Starke Artefakte im glänzenden Bereich und geringe Artefakte im matten Bereich (rechtes Bild, glänzender Bereich entspricht dem grauen Bereich links) am Beispiel des matt-glänzenden Fahrzeugmodells

4.3 Punktwolkenzuordnung

Die Punktwolkenzuordnung umfasst Methoden zur Registrierung bzw. Datenfusion der Messdaten, die durch verschiedene, unabhängige Sensoren aufgenommen wurden. Das Konzept wurde in der Theorie erarbeitet und soll am Demonstratoraufbau umgesetzt werden. Hierbei wird eine Bestimmung der Transformation der einzelnen Sensorkoordinatensysteme zu einem globalen Koordinatensystem

durchgeführt. Dazu wird ein geeignetes Objekt, in diesem Fall ein Kugelnorm, genutzt, für das aus allen Blickrichtungen die Mittelpunkte der Kugeln bestimmt werden können. Über die Bestimmung der Verschiebung und Rotation der Kugelmittelpunkte kann eine Transformationsmatrix für jeden Sensor bestimmt werden. Diese Transformation ist durchgängig gültig, solange die physikalische Position der Sensoren nicht verändert wird. Die anhand des fusionierten Gesamtdatensatz abgeleiteten Messgrößen sind hinreichend genau, da die Messunsicherheit der Längenmessungen im Bereich von Zehntel Millimetern und mehr liegen kann. Desweiteren sind die auszuwertenden Messgrößen der Defekte lokal begrenzt, weshalb sich diese meist nicht über mehrere Datensätze erstrecken.

Arbeitspaket 5: Inspektions- und Messalgorithmen

Das Ziel dieses Arbeitspaketes besteht in der Entwicklung von Algorithmen zur robusten und schnellen 3D Datenverarbeitung von Punktwolken zur Formüberwachung und Inspektion von Fahrzeugen. Zunächst wurden Testscans an lackierten Blechteilen im Labor des Fraunhofer IPA durchgeführt, um erste Testdaten für die Konzeption der Algorithmen zur 3D-Messdatenauswertung zur Verfügung zu haben. Hierfür wurde ein Testaufbau mit Linearachse und verfügbarer Lichtschnittsensorik zur 3D-Punktwolkenerfassung genutzt. Insbesondere wurden die Testdaten hinsichtlich Datenqualität und Datendichte betrachtet. Neben der Erfassung der Scandaten mit unterschiedlicher Parametrierung, wurden einige Tests zur Datenauswertung und Einpassung in den erzeugten Punktwolken durchgeführt, um eine erste Einschätzung zur Algorithmenauswahl für die 3D-Defekterkennung zu bekommen.

Teilweise können Beulen oder Kratzer so klein sein, dass sie nicht im 3D Datensatz erkennbar sein werden. Trotzdem können sie für das menschliche Auge, bspw. durch ein anderes Reflexionsverhalten oder eine andere Textur, sichtbar sein. Um auch diese kleinen Defekte zu erfassen, wurde das Verfahren „Shape from Shading“ auf seine Eignung hin untersucht. Hierbei wird eine intelligente Beleuchtung und die dadurch erzeugten Objektschatten genutzt, um Forminformationen oder Fehlstellen auch aus 2D Daten zu gewinnen. Weiterhin wurden maschinelle Lernverfahren, insbesondere Deep Learning Verfahren untersucht, um Beschädigungen in den Bilddaten zu detektieren (siehe Abschnitt 5.2).

5.1 3D Punktwolkeneinpassung für Defekterkennung und Messung

Zur Umsetzung eines historischen Vergleichs zwischen dem schadensfreien Fahrzeug und dem aktuellen Fahrzeugscan müssen die Messdaten registriert werden. Da die Messdaten im Demonstrator aus einem konstanten Blickwinkel aufgenommen werden und lediglich das Fahrzeug um einen relativ geringen Wert in dessen Ausrichtung variiert, können globale Einpassungsverfahren wie der Iterative Closest-Point-Algorithmus genutzt werden. Hierzu wurden erste Untersuchungen durchgeführt, die gezeigt haben, dass zunächst das Zusammensetzen des gesamten Fahrzeugmodells stattfinden muss, um anschließend eine genaue Registrierung umsetzen zu können. Versuche einer Einpassung eines gescannten Datensatzes einer Blechprobe mit Defekten (Dellen) gegenüber dem defektfreien Datensatz haben gezeigt, dass eine Einpassung von Detailscans zu falschen Registrierungsergebnissen führen kann. Wenn der Defektbereich relativ groß

verglichen zur gesamten erfassten Oberfläche ist, werden die Messpunkte des Defekts unter Annahme von nahezu gleichverteilten Messpunkten stärker gewichtet, weshalb die Oberfläche gegenüber der defektfreien Oberfläche eher Richtung des Materials verschoben wird. Dann würde eine Durchdringung und ein größerer Schaden ermittelt werden, was nicht der Realität entsprechen würde. Wird zunächst der Datensatz aus mehreren Sensoren fusioniert, nimmt die relative Gewichtung der Defektbereiche stark ab, weshalb das Registrierungsergebnis deckungsgleich zum historischen Datensatz ermittelt werden kann. Somit werden darauf folgende Probleme bezüglich des historischen Vergleichs vermieden.

5.2 Oberflächeninspektion, inklusive Shape from Shading

Zur Entwicklung des Software-Konzepts wurden zwei verschiedene Ansätze gegenübergestellt. Zum einen der Vergleich der aktuellen Messdaten zu vorab erfassten Messdaten, die zum Zeitpunkt nichtvorhandener Schäden erfasst wurden, oder zu einem Nominalmodell ausgewertet werden und zum anderen der lokal-adaptive Vergleich. Erstere Methoden basieren auf einem Vergleich mit historischen Daten, der durch einen Fahrzeugscan zu Zeiten ohne Fahrzeugdefekte umgesetzt werden kann. Hierbei kann über einen Schwellenwert definiert werden, welche Abweichungen welcher Größenordnung zwischen den Datensätzen signifikant sind. Hierzu müssen die Datensätze registriert werden, was mittels Best Fit-Methoden (wie z.B. dem Iterative Closest Point-Algorithmus) umgesetzt werden kann. Letztere lokal-adaptive Methoden basieren auf einer lokalen Auswertung der Messdaten, z.B. durch Ermittlung von Abweichungen von der vorherrschenden Struktur.

In Tabelle 1 sind Vor- und Nachteile möglicher Varianten (Einzelauswertung sowie globales Fahrzeugmodell) für den globalen historischen Vergleich dargestellt. In Tabelle 2 sind die Auswertestrategien gegenübergestellt, wobei die Auswertung gegenüber einem Nominalmodell (z.B. CAD-Modell) im Soll-Ist-Vergleich und gegenüber einem individuellen Fahrzeugmodell ohne Schaden im Ist-Ist-Vergleich dargestellt werden. Das Verfahren mittels Vergleich gegenüber historischen Istdaten wird bevorzugt, da ein Vorliegen von Nominaldaten nur in wenigen Fällen sicher angenommen werden kann.

Im Rahmen des Meilensteins M3 zu AP 5 wurde ein lokal-adaptives Auswerteverfahren (siehe Beschreibung unten) sowie das oben beschriebene Verfahren für den globalen Ist-Ist-Vergleich ausgewählt und das Vorgehen hierzu ermittelt. Die Evaluation der ausgewählten Konzepte musste anhand des Demonstratoraufbaus erfolgen. Dies liegt darin begründet, dass zunächst vor und nach einem Schadensfall relativ großflächige digitale Fahrzeugmodelle aufgenommen werden müssen. In Größenordnung eines Fahrzeugs war dies erst mit Hilfe des Demonstrators möglich.

Tabelle 1: Gegenüberstellung der Konzepte zur globalen Auswertung (lokale und globale Auswerteregionen)

Konzept	Pro	Contra
Einpassung am vollständigen Fahrzeugmodell (global)	Vollständige Vergleichsdaten für Matching der aufgenommenen Punktwolken vorhanden	<ul style="list-style-type: none"> ▪ Hoher Rechenaufwand bei Erstellung des Fahrzeugmodells aus gescannten Punktwolken ▪ Erstellung eines kompletten Fahrzeugmodells eventuell nicht möglich wegen Abschattungen
Einzelne Punktwolken der Sensoren (lokal)	Effizienterer Vergleich (hinsichtlich Rechenleistung, Datenmenge)	<ul style="list-style-type: none"> ▪ Zuordnung aufgrund unterschiedlicher Aufnahmeszenarien eventuell nicht gegeben → ausreichende Überlappungsbereiche müssen vorgesehen werden

Tabelle 2: Gegenüberstellung der Auswertestrategien nach Referenzdatenart (Nominal- und Istdaten)

Konzept	Pro	Contra
Ist-Ist Vergleich	Die Defekte können dezidiert Nutzungsphasen zugewiesen werden Abweichungen zwischen Soll- und Ist-Maßen (z.B. fertigungsbedingt) sind obsolet	<ul style="list-style-type: none"> ▪ Stets erneute Erfassung des Fahrzeugs notwendig ▪ Keine Vorverarbeitung der Vergleichsdaten möglich
Soll-Ist Vergleich	Keine erneute Aufnahme des Fahrzeugs notwendig Solldaten können für geeigneten Vergleich passend vorverarbeitet werden	<ul style="list-style-type: none"> ▪ Erfassung und Speicherung des Ist-Zustands bei Fahrzeugausgabe ist offen ▪ Fertigungsschwankungen werden als Fehler interpretiert ▪ Vielzahl von Sollmodellen notwendig

Zur **lokalen, adaptiven Auswertung** wurde ein neues Verfahren entwickelt, das an Konzepte der Oberflächenmesstechnik angelehnt ist. Hierzu wurden die Berechnungsmethoden nach der Norm ISO 25178 studiert und auf deren Anwendbarkeit für die Aufgabenstellung evaluiert. Die Kenngrößen der Oberflächenmesstechnik dienen dazu, Oberflächen und Abweichungen von deren vorherrschender Gestalt zu quantifizieren. Der Materialanteil S_{mr} ist eine Kenngröße bezogen auf die dreidimensionale Fläche, welcher als ein Maß für die Kompaktheit einer Oberfläche angesehen werden kann. Die Kenngröße S_{mr} wird berechnet, indem eine Offset-Ebene über die Oberfläche iteriert wird. Es wird ermittelt, ob ein Messpunkt, bzw. ein hierzu assoziiertes Volumen in Richtung des Materials oder in entgegengesetzter Richtung liegt. Über die gesamte zu evaluierende Fläche werden die beiden Klassen jeweils addiert. Als Resultat durch Iteration der Offset-Ebene vom höchsten bis zum niedrigsten Messpunkt, also vom am meisten vom Material entfernten Punkt zum

innenliegendsten Punkt, erhält man die Materialanteilkurve (für zweidimensionale Messdaten in der klassischen Oberflächenmesstechnik auch Abbott-Firestone-Kurve genannt). Die folgenden Abbildungen zeigen das entwickelte Vorgehen auf.




Abbildung 9: Erfasste, triangulierte Oberfläche eines Messobjekts (links) und Offset-Ebene in definierter Position (hier ungefähr mittig zwischen innerstem und äußerstem Messpunkt) (rechts)

Zur Ermittlung der Kenngröße S_{mr} wird die Fläche in Richtung des Materials auf eine definierte Dicke zu einem Volumen konvertiert. Durch ein Schneiden der Offset-Ebene in vielen Schritten werden Schnittflächen erzeugt, die ein Maß für die lokale Homogenität der auszuwertenden Fläche sind, vgl. Abbildung . Sind Defekte in der Oberfläche vorhanden, äußern sich diese durch eine lokale Ungleichverteilung der Messpunkte im Schnitt, sodass eine größere Anzahl an Messpunkten entweder im Defektbereich oder im defektfreien Bereich fehlt. Im gezeigten Beispiel äußert sich die Rillenstruktur des Bauteils durch ein Fehlen von Messdaten im Schnitt im Bereich der Rillen.




Abbildung 10: Volumendarstellung der Fläche (links) und Schnittfläche (rechts)

Das resultierende Ergebnis durch Iteration über ca. 1000 Schnitte wird in der Materialanteilkurve (vgl. Abbildung 1111) dargestellt. In Bereichen mit Defekten variiert die Kurve von Bereichen ohne Defekte. Somit ist es möglich, durch eine lokale Auswertung des Materialanteils über relativ kleine Evaluationsfenster eine lokal aufgelöste Aussage über Oberflächendefekte zu ermöglichen (vgl. Abbildung 12).

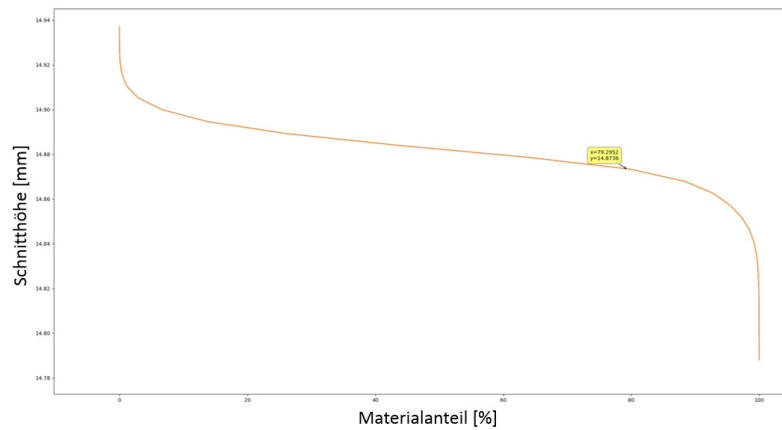


Abbildung 11: Beispielhafte Darstellung einer Materialanteilskurve




Abbildung 12: Beispielhafte Unterteilung einer erfassten Oberfläche in lokale Auswertebereiche

Die Nutzung von Shape from Shading für die Defekterkennung wurde in der Theorie sowie anhand der Evaluation von Bildern, die mit verschiedenen Beleuchtungsszenarien aufgenommen wurden, bewertet. Hierbei wurde festgestellt, dass wie in Abbildung ersichtlich, eine Reflexion der Lichtquelle auf dem glänzenden Fahrzeug entstehen kann, die eine Auswertung mit analytischer Bildverarbeitung erschwert. Desweiteren ist die Konstanzhaltung des Aufnahmeszenarios in der Praxis mit dem entwickelten Demonstratorkonzept als zu komplex zu bewerten, da eine Auswertung nach dem Shape from Shading-Verfahren im Stillstand erfolgen müsste, der Portalaufbau des Demonstrators jedoch kontinuierlich verfahren wird.

Zur Erkennung von Schäden bieten sich neuronale Netze zur Klassifikation von Schäden und deren Eingrenzung mit Bounding Boxen oder zur pixelfeinen Segmentierung an, wie in Abbildung 13 dargestellt. Dies hat den Vorteil, dass ein komplexes Beleuchtungsszenario entfallen kann, was den Hardwareaufwand für den Demonstrator erheblich reduziert. Diese Methode ist vielversprechend verglichen mit dem Shape from Shading-Ansatz, da zum einen die aufwändige Beleuchtung entfällt und zum anderen bereits lokal zugeordnete Defekte quantifiziert werden können. Der Zwischenschritt einer Rekonstruktion der Shape from Shading-Aufnahmen entfällt hier. Selbst Reflexionen der Beleuchtung auf dem Fahrzeug sind in den Aufnahmen weniger problematisch, da sie durch das neuronale Netz ignoriert werden. Hierfür wurde eine separate Klasse Reflexionen in das Training mit aufgenommen, um diese von Defekten am Fahrzeug unterscheiden zu können.

Es wurde zunächst ein Datensatz von ca. 250 Trainingsbildern, in denen die Fehlerbereiche mit Polygonen gelabelt und den unterschiedlichen Fehlerklassen zugeordnet wurden, verwendet. Weiterhin wurde ein davon unabhängiger Validierungsdatensatz erstellt, um die Erkennungsleistung des Verfahrens zu bewerten.

Insgesamt wurden verschiedene Lernverfahren untersucht, wobei sich ein Mask RCNN Verfahren als am besten geeignet herausgestellt hat, um mehrere Defektklassen zu unterscheiden. Dieses neuronale Netz kommt auch mit einer unterschiedlichen Anzahl an Fehlerbildern für die einzelnen Klassen besser als andere Verfahren zurecht. Erste Tests zeigen recht vielversprechende Ergebnisse bei der Defekterkennung, zumal die verwendete Datenbasis noch recht klein war. Eine sukzessive Erweiterung der gelabelten Bilddaten sowie der Fehlerklassen ist jedoch notwendig, um eine robuste Erkennung mit möglichst geringer False-Positive-Rate zu erreichen.



Abbildung 13: Bildhafte Auswertung und Reflexion sowie Schattenwurf auf den Fahrzeugen




Abbildung 14: erkannter Felgenschaden in grün markiert

Arbeitspaket 6: Bedienoberfläche

Zur Darstellung der erkannten Defekte wurde eine grafische Bedienoberfläche implementiert, in der die einzelnen Bilder angezeigt und die Fehlerbereiche farbcodiert dargestellt sind. Dies ist auch für eine spätere Interaktion des Bedieners zur Bestätigung des gefundenen Defekts hilfreich, um das lernende System durch Nachtrainieren weiter verbessern zu können.



Abbildung 14: Entwickelte grafische Bedienoberfläche zur Anzeige der erkannten Fahrzeugschäden, hier Dellen an der Tür in dunkelblau markiert, Kratzer in hellgrün.

Arbeitspaket 7: Demonstrator



Abbildung 15: Demonstratoraufbau beim griechischen Partner in Thessaloniki

Die geplanten Projektarbeiten des Fraunhofer IPA in Arbeitspaket 7 haben sich durch den erheblich verspäteten Demonstratoraufbau bei den griechischen Projektpartnern verzögert, da unter anderem Hardwarekomponenten von griechischen Lieferanten sehr viel später als geplant geliefert wurden, und konnten dann aufgrund der Corona-Pandemie nicht mehr als Vororttermine zum Testen der Software am Demonstrator durchgeführt werden. Außerdem wurden die Punktwolken im Demonstrator teilweise mit realsense-Sensoren aufgenommen, deren Auflösung für eine zuverlässige 3D-Defekterkennung nicht ausreicht, da die Messpunktdichte und die Höhenauflösung deutlich zu gering ausfällt, um kleinere Dellen oder Verformungen zu erkennen (siehe Abb. 16).




Abbildung 16: Punktwolke zur Seitenansicht eines Peugeot in schlechter Datenqualität

Punktwolken, die mit dem von EVT entwickelten hochauflösenden 3D-Sensor in Thessaloniki aufgenommen wurden, umfassten nur wenige Zentimeter breite Messbereiche, so dass auf dieser Basis keine Tests mit den entwickelten 3D-Inspektionsverfahren zum Ist-Ist-Vergleich durchgeführt werden konnten. Daher wurden die Arbeiten in Arbeitspaket 5 zur Defekterkennung auf Basis von Maschinellen Lernverfahren intensiver verfolgt, da hierfür Bildmaterial von Fahrzeugen am IPA zur Verfügung stand.

Voraussichtlicher Nutzen, Verwertbarkeit des Ergebnisses

Die wirtschaftlichen Erfolgsaussichten nach Projektende werden weiterhin als sehr gut eingeschätzt. Dies hat auch die vom Fraunhofer IPA durchgeführte Befragung von Endanwendern zu deren Anforderungen an ein optisches Fahrzeuginspektionssystem sowie die weiteren Recherchen gezeigt. Die im Projekt erzielten Ergebnisse werden wirtschaftlich hauptsächlich von dem deutschen und dem griechischen KMU-Partner verwertet. Die wissenschaftliche Verwertung wird vom Fraunhofer IPA und vom griechischen Forschungspartner im Verbund übernommen.

Das im Projekt angestrebte System wurde modular aufgebaut, so dass es möglich ist, hinsichtlich Funktionsumfang und Preis, verschiedene Fahrzeugverleih- und Flottenmanagementsysteme

basierend auf optischer Messtechnik auf dem Markt anzubieten. Auf diese Weise können auf die jeweiligen Endanwenderanforderungen angepasste Angebote erstellt werden. Weiterhin ist neben dem Gesamtsystem auch angedacht, die einzelnen Komponenten wirtschaftlich zu vermarkten. Das Fraunhofer IPA wird die im Rahmen des Vorhabens erzielten Ergebnisse (Algorithmen) als Softwaremodule an oder über die Projektpartner lizenzieren.

Für den Ergebnistransfer waren zahlreiche Maßnahmen vom Fraunhofer IPA geplant, um den potentiellen Anwenderkreis über das Vorhaben und die resultierenden Ergebnisse zu informieren. Aufgrund der Corona-Pandemie konnten aber insbesondere Workshops, Messeauftritte und Konferenzvorträge nicht wie geplant stattfinden und werden nun sukzessive nachgeholt. So sind aktuell Messeauftritte auf der Vision in Stuttgart vom 5.-7. Oktober 2021 sowie auf der Control im Mai 2022 geplant. Weiterhin werden die Ergebnisse des Fraunhofer IPA beim Open-Lab-Day am 10. Dezember 2021 der Öffentlichkeit präsentiert und hier insbesondere die entwickelten, KI-basierten Defekterkennungsverfahren als Softwaredemonstrator gezeigt.

In Bezug auf die wissenschaftliche und wirtschaftliche Anschlussfähigkeit werden die im Projekt entwickelten Software-Algorithmen zur Defekterkennung und Formüberwachung für eigene mess- und prüftechnische Untersuchungen am Fraunhofer IPA weiterverwendet. Außerdem steht das Fraunhofer IPA den Verbundpartnern für Anpassungen und Weiterentwicklungen der entwickelten Auswertalgorithmen, z.B. in Bezug auf spezifische Endkundenanforderungen, zur Verfügung. Es wird davon ausgegangen, dass die entwickelten Algorithmen in einem breiten Spektrum von Anwendungen eingesetzt werden können, z.B. auch in Produktionsumgebungen zur Bauteilerkennung und Qualitätskontrolle. Intelligente Aufnahme- und Messmethoden werden von der Industrie ständig benötigt. Der Einfluss der im Projekt erzielten Ergebnisse wird über den Hauptanwendungsfall hinausgehen und weitere Forschungs- und Entwicklungsarbeiten können darauf aufgebaut werden. Insbesondere wird der KI-basierte Ansatz zur Defekterkennung und Klassifizierung wird bereits im Rahmen des KI-Fortschrittszentrums am Fraunhofer IPA weiterverfolgt. Unter anderem soll hier mit Hilfe einer geeigneten Vorverarbeitung der Bilddaten und einer KI-basierten Fahrzeugteilesegmentierung die Zuverlässigkeit der Defekterkennung und Klassifikation erhöht werden, insbesondere für sehr kleine Beschädigungen wie Kratzer oder Felgenschäden.

Während der Durchführung des Vorhabens dem Zuwendungsempfänger bekannt gewordener Fortschritt auf diesem Gebiet bei anderen Stellen

Bei Projektbeginn wurde eine ausführliche Recherche durchgeführt, welche anderen Scansysteme für Fahrzeuge bereits verfügbar sind bzw. sich in Entwicklung befinden. Ein zum INVIVO-System vergleichbares System konnte nicht ermittelt werden. Auch während der weiteren Durchführung des Projekts hat sich gezeigt, dass zwar im Bereich der Fahrzeugscanner auch an anderen Stellen Entwicklungsarbeiten stattfinden, die den Istzustand der Fahrzeuge beim Durchfahren in Bildfolgen erfassen. Eine automatisierte Erkennung von Schäden am Fahrzeug wie z.B. Kratzer oder Dellen ist nicht verfügbar und auch eine 3D-Erfassung der Fahrzeugkarosserie beim Durchfahren des Fahrzeugs ist bislang nicht bekannt geworden.

Erfolgte oder geplante Veröffentlichungen des Ergebnisses

Zum Verbundprojekt INVIVO gibt es eine eigene Webseite, wo das Projekt beschrieben ist und einige Projektergebnisse, vor allem der Demonstratoraufbau, mit Filmen etc. dargestellt sind:

<https://invivo-project.eu>

Weiterhin wurde im Rahmen des INVIVO-Projekts eine Masterarbeit betreut, in der u.a. Verfahren zur lokal adaptiven Auswertung für Oberflächenmessdaten untersucht und auch auf INVIVO-Messdaten angewendet wurden. Die Arbeit wurde 2020 fertiggestellt:

Manakkaparambil Ali, Nowfal: "Morphological point cloud operations concerning the material ratio for the simulation of a real surface manipulation", 97 Seiten, 2020, Hochschule Jena.

Weitere Veröffentlichungen wurden aufgrund der Corona-Pandemie verschoben und sind erst ab Herbst/Winter 2021 geplant. Konkret sind hier bereits vorgesehen:

- Präsentation der Ergebnisse auf der Messe Vision in Stuttgart, die vom 5.-7. Oktober 2021 stattfindet
- Präsentation der entwickelten KI-basierten Verfahren zur Defekterkennung beim Open-Lab-Day am 10. Dezember 2021 beim Fraunhofer IPA in Stuttgart