



**Künstliche Intelligenz
und maschinelles
Lernen im automobilen
Umfeld**



KI Absicherung – Schlussbericht

Berichtszeitraum: 01.07.2019 - 30.06.2022

Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR)

Version 1.0

Laufzeit des Vorhabens: 01.07.2019 – 30.06.2022

Zuwendungsempfänger: DLR

Förderkennzeichen: 19A19005V

Fälligkeitsdatum: 31.12.2022

Erstellungsdatum: 19.12.2022

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages

**Ein Projekt entwickelt von der
VDA Leitinitiative
autonomes und vernetztes Fahren**





DOKUMENTENINFORMATION

KONTAKT

Kay Gimm

Institut für Verkehrssystemtechnik

Deutsches Zentrum für Luft- und Raumfahrt e.V.

38108 Braunschweig

Tel.: +49 (0) 531-295-3453

Fax: +49 (0) 531-295-3402

Email: kay.gimm@dlr.de

VERSIONSÜBERSICHT

Version	Datum	Kommentar	Autor
V0.1	27.09.2022	Erzeugung Template	Kay Gimm
V0.2	12.10.2022	Entwurf Kapitel 2	Clemens Schicktanz
V0.3	24.10.2022	Überarbeitung Kapitel 2	Clemens Schicktanz
V0.4	07.11.2022	Erstellung Kapitel 1	Clemens Schicktanz
V0.9	22.11.2022	Finalisierung Entwurf	Kay Gimm
V1.0	19.12.2022	Einarbeitung externes Feedback	Kay Gimm



INHALTSVERZEICHNIS

1. EINFÜHRUNG.....	3
1.1 Aufgabenstellung	3
1.2 Voraussetzungen	3
1.2.1 BMW-Fachprogramm “Neue Fahrzeug- und Systemtechnologien“	3
1.2.2 KI-Strategie der Bundesregierung.....	5
1.3 Planung und Ablauf des Vorhabens	5
1.4 Wissenschaftlicher und technischer Stand	10
1.4.1 Corner Cases	10
1.4.2 Daten für Training und Test erzeugen	10
1.5 Zusammenarbeit mit anderen Stellen.....	11
2. ERGEBNISSE	13
2.1 Darstellung der Verwendung der Zuwendung und des erzielten Ergebnisses.....	13
2.1.1 Recherche zu verkehrssituativen Corner Cases.....	13
2.1.2 Beitrag zur Corner Case Taxonomie.....	13
2.1.3 Realistischer Anteil und Verteilung von VRU an einer urbanen Kreuzung	14
2.1.4 Detektion kritischer verkehrssituativer Corner Cases in Trajektorien- daten	15
2.1.5 Synthetische Nachbildung der kritischsten Szene	21
2.2 Wichtigste Positionen des zahlenmäßigen Nachweises	22
2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit	22
2.4 Voraussichtlicher Nutzen – Verwertbarkeit des Ergebnisses im Sinne des Verwertungsplanes.....	23
2.5 Bekannter Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen	23
2.6 Erfolgte und geplante Veröffentlichungen.....	23
3. REFERENZEN	24
LITERATURVERZEICHNIS	24



1. EINFÜHRUNG

1.1 Aufgabenstellung

Das Projekt KI Absicherung hat zum Ziel, die Sicherheit von KI-basierten Funktionsmodulen für das hochautomatisierte Fahren nachweisbar zu machen. Dafür wird an einer allgemeinen Absicherungsstrategie für KI-Funktionen gearbeitet. Diese soll schlussendlich als Industriekonsenses gelten und in Standardisierungsgremien eingebracht werden. Das DLR hat sich dabei im Arbeitspaket AP2.2 „Corner Cases“ des Teilprojekts TP2 „Synthetische Daten“ engagiert. Im Rahmen des TP2 wird eine Werkzeugkette zur Produktion von synthetischen Daten aufgebaut, mit denen KI-Module trainiert und getestet werden können. Ziel ist es, einen prototypischen Datensatz zu entwickeln, der verwendet werden kann, um die Eignung synthetischer Daten als Ersatz für Realdaten zu bewerten.

Speziell bestand für das DLR die Aufgabe, im E2.2.2 Modelle und Daten inkl. der Ideen für Corner Cases (CC) mit eigenen Ansätzen und datenbasierten Experimenten zu Trajektorien von dynamischen Objekten einzubringen.

Die DLR-Aufgaben im E2.2.4 zielten darauf ab eine Methodik für die systematische Ableitung und Erzeugung von CC zu erzeugen, indem kritische Situationen identifiziert und deren Relevanz für das automatisierte und vernetzte Fahren bewertet wird. Hierzu sollten etablierte Methoden der Verkehrskonflikttechnik erweitert werden.

Der Beitrag vom DLR im E2.2.7 zu bewerteten Corner Cases beinhaltet die Erfassung und Bereitstellung von Daten.

Nicht in der VHB von KI Absicherung verankert, aber trotzdem nennenswert ist, dass das DLR eine vernetzende Brückenfunktion in den Projekten der KI Familie und zu den Großprojekten SetLevel4to5 und VV-Methoden, welche sich ebenfalls mit der Thematik der Absicherung von automatisierten Fahrfunktionen beschäftigen, hat. Die Aktivität wird aus dem sog. „TPX“ heraus durchgeführt, welches formal in KI Data Tooling in TP4 verortet ist. Vor diesem Hintergrund wurde u.a. der Informations- und Datenaustausch mit anderen Projekten vorangetrieben und die Veröffentlichung eines gemeinsamen Datensatzes aus KI-Absicherung unterstützt. Konkret wurde z.B. ein synthetischer Datensatz aus KI Absicherung für KI Data Tooling verfügbar gemacht, so dass dieser unmittelbar Verwendung fand, bevor in KI Data Tooling projekteigene Daten generiert worden sind.

1.2 Voraussetzungen

Das Verbundprojekt KI Absicherung wurde unter Bezug zum BMWi/BMWK-Fachprogramm „Neue Fahrzeug- und Systemtechnologien“ (NFST) sowie zur KI-Strategie der Bundesregierung durchgeführt.

1.2.1 BMW-Fachprogramm „Neue Fahrzeug- und Systemtechnologien“

Das Fachprogramm formuliert u.A. den Bedarf für produkt- und anwendungsnahe Forschungsmaßnahmen in der Säule „Automatisiertes Fahren“, um die „industrielle und wissenschaftliche Innovationskraft Deutschlands im Bereich des automatisierten Fahrens zu stärken“. KI Absicherung weist einen konkreten Bezug zur Programmsäule „Automatisiertes Fahren“ des BMWi-Fachprogramms auf. KI-Absicherung



- greift die im Themenfeld „Innovative Sensorik und Aktoriksysteme“ definierten Herausforderungen auf, in dem es die Grundlage für neue (KI basierte) Wahrnehmungsfunktionen, die eine Umgebungserfassung in komplexen Szenarien für hoch- und vollautomatisches Fahren erst ermöglicht, schafft.
- erarbeitet Lösungen für die im Themenfeld „Angepasste Testverfahren und Validierung“ dargestellte Herausforderung der Absicherung automatisierten Fahrfunktionen durch Entwicklung geeigneter Verfahren und Methoden, die die Grundlage für den Einsatz der Schlüsseltechnologie KI im automatisierten Fahren schaffen.

Die konkreten Beiträge des Vorhabens KI-Absicherung zu den innerhalb des BMWi-Fachprogramms in den beiden benannten Themenfeldern formulierten Forschungszielen werden in nachfolgender Tabelle konkretisiert:

Forschungsziel	Beitrag KI-Absicherung
Themenfeld „Innovative Sensorik und Aktoriksysteme“	
Weiterentwicklung Sensorik- und Aktoriksysteme und dazugehöriger Architektur	<p>Die Komplexität urbaner Szenarien lässt beim autonomen Fahren eine klassische, regelbasierte Programmierung von Algorithmen, besonders für das Szenenverstehen, nicht mehr zu. Im Vorhaben wurden die Potenziale KI basierter Wahrnehmungsfunktionen erschlossen.</p> <p>Hierfür bedarf es des Nachweises einer ausreichenden Robustheit bzw. Ausfallsicherheit derartiger Systeme. Entsprechend wurden im Vorhaben die Einflussgrößen auf die Sensorik selbst als auch die Auswirkungen auf das Ergebnis multisensorieller Wahrnehmung durch Erweiterung der Sensorik – z.B. um Tiefendaten und LiDAR-Sensorik) untersucht, qualifiziert und quantifiziert.</p>
Themenfeld „Angepasste Testverfahren und Validierung“	
Neuartige Indikatoren, Testverfahren und Testmethoden / Entwicklung von standardisierbaren Tests und Testanforderungen	<p>Den Kern des Vorhabens stellte die Definition von KPI zur Bestimmung der Wirksamkeit der KI-spezifischen Analyse-Methoden und -Maßnahmen dar.</p> <p>Diese Argumentation für ein methodisches Vorgehen zur Absicherung von KI-Funktionen wurde durch die Entwicklung und Nutzung geeigneter Testmethoden überprüft und mittels einer Teststrategie und eines Testplans generalisiert. Die entwickelte Teststrategie und der Testplan können als Ausgangspunkt für die Produktfreigabe KI-basierter Wahrnehmungsfunktionen dienen.</p>
Gewährleistung der funktionalen Sicherheit	<p>Im Vorhaben wird erstmalig eine Nachweismethodik zur quantitativen und qualitativen funktionalen Absicherung einzelner KI-Funktionen entwickelt. Hierfür wurde ein</p>



Forschungsziel	Beitrag KI-Absicherung
	Evidenz-basierter Nachweis der Einhaltung definierter Gütekriterien geführt. Das systematische und gesamtheitliche Vorgehen zur Argumentation der Absicherbarkeit einer spezifischen KI-Funktion wurde mit dem Ziel einer Verallgemeinerung über den spezifischen Use Case Fußgängererkennung hinaus weiterentwickelt.

Tabelle 1: Beiträge des Vorhabens KI-Absicherung zu den Forschungszielen des BMWi-Fachprogramms in der Programmsäule Automatisiertes Fahren

1.2.2 KI-Strategie der Bundesregierung

Die Bundesregierung hat zwölf prioritäre Handlungsfelder formuliert, „um die Zukunft der KI und deren Nutzung in Deutschland und Europa mitgestalten zu können“. Als ein zentrales Vehikel für die Umsetzung dieser Handlungsfelder wird die Forschungsförderung benannt. Das Vorhaben KI-Absicherung (im engeren und die KI-Projektfamilie im weiteren Sinn) hat unmittelbar zwei dieser Handlungsfelder adressiert :

- Forschung in Deutschland und Europa stärken, um Innovationstreiber zu sein

Erklärbarkeit und Transparenz von KI sind für uns der Schlüssel für das Vertrauen in die KI. Für eine Vielzahl von Anwendungen der KI stellt sich die Technologie jedoch noch als sogenannte „Blackbox“ dar: Es ist für Nutzer und Betroffene eines KI-Systems oft weder nachvollziehbar noch transparent, wie das System zu Entscheidungen oder Ergebnissen gekommen ist; dies gilt schon für algorithmenbasierte Systeme zur Entscheidungsvorbereitung und erst recht für autonom arbeitende und entscheidende Systeme. Entscheidungen müssen sich nachvollziehen lassen, damit KI-Systeme als „trusted AI“ akzeptiert werden können und rechtlichen Anforderungen genügen.

- Daten verfügbar machen und Nutzung erleichtern

Aufgrund der hohen Sicherheitsanforderungen im Automobilbereich kommt dort der Zuverlässigkeit von KI-Verfahren eine zentrale Rolle zu. Hierfür ist die Gewinnung ausreichender Trainingsdaten von besonderer Bedeutung. Zudem gilt es, auch mit Blick auf zukünftige Zulassungen neue Verfahren, Methoden und Gütekriterien zu entwickeln.

Vor diesem Hintergrund ist eine enge unternehmensübergreifende Zusammenarbeit der Automobilindustrie bei der Erzeugung/Aufnahme, Verwaltung und Auswertung von Fahr- und Sensordaten gefragt. Nur durch eine solche Kooperation zur Realisierung und Absicherung von KI-Systemen für das automatisierte Fahren wird sich die internationale Wettbewerbsfähigkeit künftig sicherstellen lassen.

1.3 Planung und Ablauf des Vorhabens

Für die Ausplanung und Realisierung des Vorhabens wurde eine Projektstruktur mit einer Unterteilung in fünf Teilprojekte (TP) definiert. Die Hauptschwerpunkte und Zielsetzungen der einzelnen Teilprojekte lassen sich folgendermaßen zusammenfassen:

Teilprojekt 1 (TP1) mit dem Kurztitel „KI-Funktion“ lieferte den beispielhaften aber praxisrelevanten Untersuchungsgegenstand für die Erforschung einer Absicherungsmethodik



für KI-Algorithmen. Hierzu wurden Algorithmen zur KI-basierten Fußgängererkennung entwickelt. Ziel war es den Stand der Technik repräsentativ abzudecken, wobei sich auf tiefe neuronale Netze, engl. Deep neural networks (DNNs) beschränkt wurde. Das erste Teilprojekt untergliederte sich hierbei in fünf Arbeitspakete:

- AP1.1 „Technische Plattform“ diente der Bereitstellung der technischen Plattform, der Projektinfrastruktur für alle weiteren APs und somit sämtliche für das Projekt notwendigen Tools und Arbeitsprozesse.
- AP1.2 „Anforderungen (Performance-KPIs)“ widmete sich der systematischen Erfassung von quantitativen und qualitativen Anforderungen an eine synthetisierte Datengenerierung an TP2. Zudem wurden in AP1.2 auch die funktionalen Anforderungen und Gütekriterien für die Entwicklung der KI-Funktionalität definiert.
- AP1.3 „Implementieren von Algorithmen zur Fußgängererkennung“ stellte die Basisalgorithmen zur Fußgängererkennung aus monoskopischen Bildsequenzen bereit. Diese Algorithmen basieren auf DNNs und wurden im Wesentlichen mithilfe der von TP2 bereitgestellten Daten generiert. Damit stellen sie die funktionale Basis für TP 3 und 4 bereit.
- AP1.4 „Erweiterung der Fußgängererkennung um Tiefendaten“ widmete sich der Entwicklung von Algorithmen zur Prädiktion und Tracking von 3D Bounding Boxen von Fußgängern in Weltkoordinaten. Zu diesem Zwecke wurden die Bilddaten mit Tiefendaten aus der Simulation angereichert.
- AP1.5 „Erweiterung um Posenschätzung“ entwickelte Algorithmen zur Fußgänger Posenschätzung, die im Gegensatz zur vergleichsweise groben Lokalisierung von Fußgängern mittels Bounding Boxen auf die Bestimmung bzw. Schätzung der aktuellen Körperhaltung abheben.

Teilprojekt 2 (TP2) mit dem Kurztitel „Generieren von synthetischen Lern- und Testdaten“ stellte dem Konsortium einen synthetischen Datensatz zur Verfügung, der neben den einzelnen monoskopischen Bilddaten auch die korrespondierenden Metadaten enthält. Dies Metadaten waren hierbei von besonderer Bedeutung für die Bestimmung bzw. den Abgleich der Performance und Qualitätsmetriken der KI Verfahren mit der sog. Ground Truth aus der Simulation. Das zweite Teilprojekt untergliederte sich hierbei in fünf Arbeitspakete:

- AP2.1 „Toolkette für synthetische Datenerzeugung“ erarbeitete eine technische Verarbeitungskette entwickelt, die alle Verarbeitungsschritte umfasst, um von einer formalen Spezifikation einer Verkehrsszene zu den simulierten Sensordaten zu gelangen.
- AP2.2 „Corner Cases“ hatte zum Ziel Situationen zu identifizieren (Szene samt Kontext und dynamischen Objekten, in der die KI-Funktionalität ein nicht erwartetes und funktional nicht hinlängliches Ergebnis liefert, obwohl ein korrektes Verhalten erwartbar gewesen wäre. Des Weiteren fungierte AP2.2 als zentraler „Gate-Keeper“ für die Anforderungen an die Datengenerierung im gesamten Projekt. In dieser Rolle werden alle eingehenden Datenanforderungen konsolidiert und priorisiert an AP2.5 weitergeleitet.
- AP2.3 „Abstraktion von Sensorik“ beschäftigte sich mit der Frage der Übertragbarkeit von KI-Funktionen bezüglich ihrer Absicherbarkeit bei Änderung der Sensorik. Weiterhin wurde die Übertragbarkeit der KI-Funktionen bei Änderung der Sensorik



durch Methoden des Transfer Learnings untersucht, sowie Konzepte zur Anpassung der Transfer Learning Methoden erarbeitet.

- AP2.4 „Bewertung synthetischer Daten“ erarbeitete eine Methode zur vergleichenden Bewertung von Datensätzen unterschiedlicher Qualität.
- AP2.5 „Datengenerierung und Noisy Data“ generierte synthetische Trainings- und Validierungsdaten unter Einbezug von bewussten Verunreinigungen bzw. Störungen von Sensordaten.

Teilprojekt 3 (TP3) mit dem Kurztitel „Methoden und Maßnahmen zur Absicherung von KI“ baute einen Werkzeugkasten aus bekannten und neuen Methoden und Maßnahmen zur Absicherung von KI auf. Hierzu wurden bestehende Ansätze angepasst, bewertet und mit dem Blick auf die Absicherbarkeit der zugrundeliegenden KI-Funktion erweitert.

- AP3.1 „Tracking State-of-Research“ übernahm die Aufgabe der Analyse und Überwachung der Forschungslandschaft sowie die Bewertung der entwickelten Mechanismen auf ihren Mehrwert hinsichtlich eines möglichen Beitrags zu einer stringenten Sicherheitsargumentation.
- AP3.2 „Wirksamkeits- und Sicherheits-KPIs für Machine Learning“ fokussierte auf die Identifikation und Belastbarkeit von Qualitätsmetriken.
- AP3.3 bis AP3.5 setzen sich explizit mit Methoden und Maßnahmen auseinander, die entweder kein (AP3.5 „Blackbox Methoden und Maßnahmen“), ein beschränktes oder aber über vollständiges (AP3.4 „White-/Greybox Methoden und Maßnahmen“) Wissen über die dahinterliegende KI Funktion haben, oder sogar funktionsverändernd wirken (AP3.3 „Funktional verändernde Methoden“).
- AP3.6 „Aggregierte Methoden und Maßnahmen“ setzte sich mit der Kombination von Methoden und Maßnahmen und deren Mehrwert hinsichtlich der Absicherbarkeit auseinander.

Teilprojekt 4 (TP4) mit dem Kurztitel „Gesamtheitliche KI-Absicherungsstrategie“ hatte zum Ziel die Definition und exemplarische Umsetzung eines systematischen Vorgehens zur Formulierung einer gesamtheitlichen Argumentation (Assurance Case) zur Absicherung einer KI-Funktion (Fußgängererkennung) vorzunehmen.

- AP4.1 „Strukturierung und Formalisierung des Eingaberaums“ wurde der Grundkontext für die Absicherung der Erkennung von Fußgängern im urbanen Kreuzungsbereich definiert und unter Verwendung einer geeigneten Beschreibungssprache beschrieben. Zudem war das Ziel eine Formalisierung und Strukturierung des gesamten Eingaberaums (Domänenanalyse) der KI-Funktion hinsichtlich funktionsrelevanter Kontextelemente (z.B. Verkehrsteilnehmer, Wetter, Objekte, Lichtverhältnisse) und Kontextdimensionen (Eigenschaft eines Kontextelementes oder eines Umwelteffektes) unter Nutzung der zu berücksichtigenden Variationsmöglichkeiten und Corner Cases aus AP2.2 zu erarbeiten und in eine Ontologie zu überführen. Außerdem wurden physikalische Effekte und bekannte Zusammenhänge zwischen Einflussfaktoren formuliert („A-priori-Wissen“).
- AP4.2 „Gesamtstruktur der Argumentation“ hatte sich zum Ziel gesetzt, die Sicherheitsziele der eingesetzten Funktion (z.B. jeder relevante Fußgänger wird rechtzeitig erkannt, so dass ausgewichen oder gebremst werden kann), die geforderten Zielgrößen (zulässigen Wertebereiche), der KI-Gesamtfunktionskontext als auch die



übergeordnete Systemarchitektur – soweit zum Nachweis der Absicherbarkeit benötigt – zu definieren.

- AP4.3 „Argumentation für eine abgesicherte KI-Funktion“ nahm die Arbeiten unter der Prämisse an, dass eine KI-Funktion aufgrund der inhärenten Komplexität und Datenabhängigkeit schwierig als alleinstehende Funktion ohne zusätzliche Maßnahmen als sicher argumentiert werden kann. Entsprechend war es das Ziel des Arbeitspaketes ein Vorgehen zur systematischen Herleitung einer Sicherheitsargumentation auf Basis von Evidenzen basierend auf den Methoden und Maßnahmen aus TP3 und AP4.4 exemplarisch zu erarbeiten. Dies geschah ohne den Anspruch einen vollständigen Sicherheitsnachweis für eine konkrete Umsetzung einer KI basierte Fußgängererkennung erarbeiten zu können.
- AP4.4 „Testmethoden und Wirksamkeitsuntersuchung“ hat sich zum Ziel gesetzt Testmethoden zur Anwendung zu bringen, mit denen es möglich ist die in AP4.1 durchgeführte Domänenanalyse und die in AP4.2 definierten Sicherheitsziele zum einen eine Abdeckung des Eingaberaums und zum anderen die Wirksamkeit der Einzelmaßnahmen zu untersuchen
- AP4.5 „KI-Teststrategie und KI-Testplan“ widmete sich dem allgemeinen Vorgehen zum Testen einer KI-Funktion. Welche Teststrategie vor dem Hintergrund der Absicherbarkeit von KI-Funktionen am besten geeignet scheint, wurde hierbei unabhängig von der konkreten Funktionsausprägung betrachtet. Darauf aufbauend war das Ziel für die KI-Funktion Fußgängererkennung auf Basis des konkreten Assurance Case unter Verwendung der KI-Teststrategie auszuarbeiten, welcher KI-Testplan geeignet erscheint.

Teilprojekt 5 (TP5) mit dem Kurztitel „Projektmanagement und Dissemination“ hatte eine querschnittliche Rolle innerhalb des Projektes KI-Absicherung. Die Hauptaufgabe dieses TP bestand darin, sowohl organisatorische als auch technisch-inhaltliche Schnittstellen unter den einzelnen Partnern und Arbeitspaketen zu schaffen und zu pflegen.

- AP5.1 „Projektmanagement“ hatte die übergeordnete Aufgabe der technischen Gesamtkoordination mit der inhaltlichen und zeitlichen Organisation der technischen Arbeiten sowie die Sicherstellung der Qualität der Ergebnisse. Hierzu wurden die Arbeiten der einzelnen Arbeitspakete inhaltlich abgestimmt und nachverfolgt sowie der Arbeitsfortschritt hinsichtlich der definierten Meilensteine bestimmt. Bei inhaltlichen Konfliktsituationen und Planabweichungen wurden Vorschläge für adäquate Gegenmaßnahmen erarbeitet.
- AP5.2 „Ergebnisverbreitung“ hatte die Aufgabe die Kommunikation des Vorhabens und dessen Ergebnissen nach außen voranzutreiben. Eine Hauptaufgabe bestand in der zielgruppengerechten Aufbereitung und Zur-Verfügung-Stellung von relevanten Projektinformationen durch geeignete Kommunikationsmittel. Zum anderen wurden Veranstaltungen (Halbzeit- und Abschlusspräsentation) konzipiert, vorbereitet und umgesetzt.
- AP5.3: "Kommunikation mit Normungsgremien" unterstützte das Vorhaben im Allgemeinen und TP4 im Besonderen bei der Kommunikation mit relevanten Normungsgremien und Zertifizierungsstellen. Hierfür gilt es zunächst, relevante Gremien, Aktivitäten und Organisation zu identifizieren. Ausgangspunkt hierfür waren die zu Vorhabensbeginn bekannten, für das Vorhaben KI Absicherung relevanten Normen. In Anbetracht der immer greifbareren Markteinführung automatisierter



Fahrfunktionen war davon auszugehen, dass sich über die Projektlaufzeit hinweg relevante Normierungs- und Standardisierungsaktivitäten – sowohl im Themenbereich der Absicherung als auch im Technologiefeld KI – ausweiten würden. Diese galt es zu beobachten. AP5.3 trug darüber hinaus die Verantwortung dafür, dass das „Zugehen“ und „Einbinden“ der relevanten Akteure projektweit abgestimmt stattfindet.

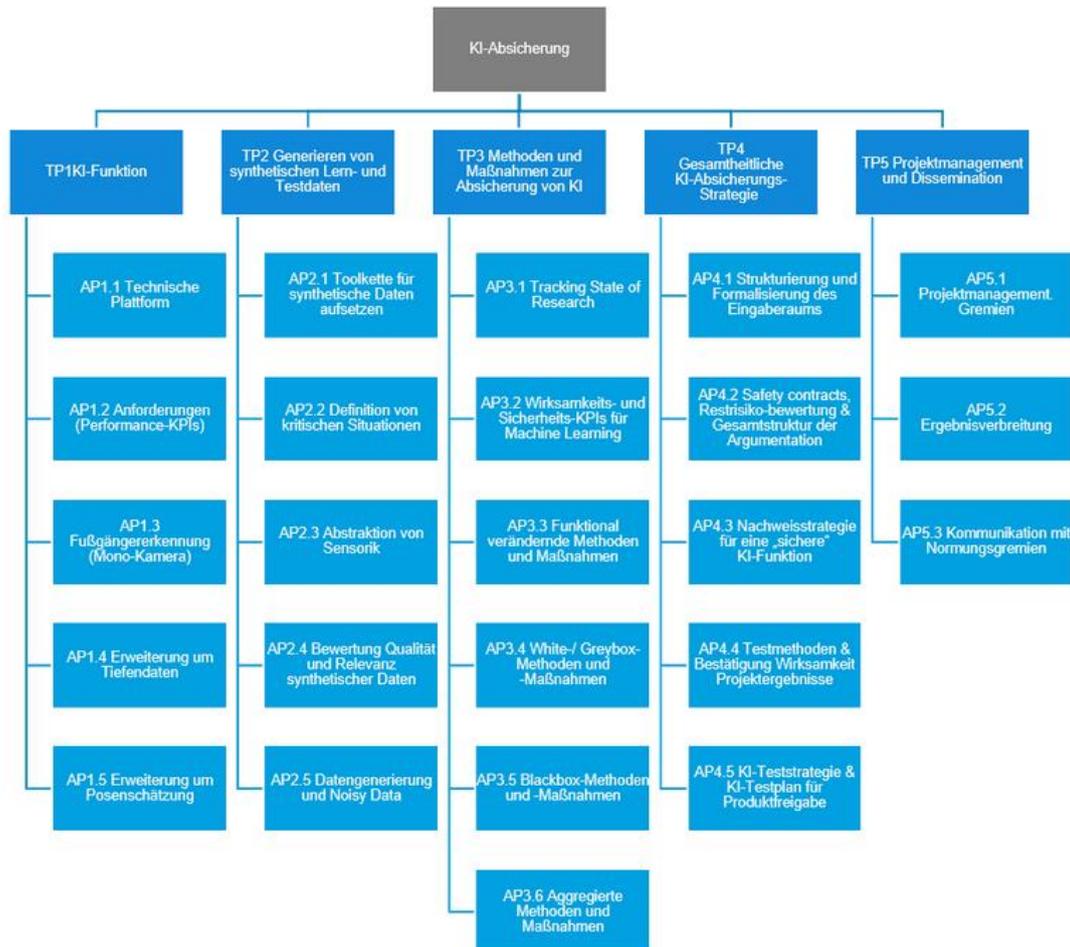


Abbildung 1 - Projektstruktur von KI Absicherung

Abgesehen von einem Präsenztreffen in München zu Beginn des Projektes fand der Austausch im AP2.2 digital über 2-wöchentliche Telefonkonferenzen statt. Dabei wurde der aktuelle Arbeitsstand diskutiert und das weitere Vorgehen geplant.

Zu Beginn des Projektes erfolgte die Zusammenarbeit noch etwas enger, weil an gemeinsamen Themen gearbeitet wurde. Da im Verlauf des Projektes das DLR vor allem Methoden auf den intern verfügbaren Trajektorienaten entwickelt hat und bei den Projektpartnern die Generierung und Analyse der synthetischen Szenenbilder im Fokus standen, reduzierte sich zwischenzeitlich der Abstimmungsaufwand leicht. Zum Ende des Projektes gab es wieder mehr Zusammenarbeit, da die Ergebnisse zusammengefügt und gemeinsam verwertet wurden.



1.4 Wissenschaftlicher und technischer Stand

1.4.1 Corner Cases

Ein Corner Case (CC) beschreibt Daten, die unregelmäßig auftreten, eine potenziell kritische Situation beschreiben und in Datensätzen, wenn überhaupt, nur selten auftreten. Mit der Verbreitung von automatisierten Fahrzeugen steigt die Wahrscheinlichkeit dafür, dass die Fahrzeuge in eine derartige unerwartete Situationen gelangen. Daher ist es wichtig, CC bei der Entwicklung von automatisierten Fahrfunktionen zu berücksichtigen (Bogdoll et al. 2021).

Um die diversen Auftrittsmöglichkeiten von CC strukturiert abarbeiten zu können, wird das Ziel verfolgt, CC zu systematisieren. Breitenstein schlägt zum Beispiel für die Bilderkennung eine Gruppierung nach dem Level der Komplexität in der Detektion des CC vor. Diese Level sind nach aufsteigender Komplexität geordnet, das Pixel-Level, Domain-Level, Objekt-Level, Szenen-Level, Szenario-Level (Breitenstein et al. 2020). Weiterhin existiert nach Breitenstein eine Orientierungshilfe für die Erkennung der Corner Cases in den unterschiedlichen Levels (Breitenstein et al. 2021). Die Ergebnisse der zuvor vorgestellten Inhalte werden von Heidecker aufgegriffen und erweitert, indem die CC nach dem Sensor (Kamera, Lidar, Radar) unterschieden werden (Heidecker et al. 2021). Damit wird eine anwendungsorientierte Konzeptualisierung ermöglicht. Demnach existieren Untersuchungen von CC auf dem Bereich der Sensorik und Bilderkennung. Deutlich unerforschter ist der Bereich der Corner Cases in Trajektorien-Datensätzen für das automatisierte Fahren. Neben den Arbeiten aus dem Projekt KI Data Tooling (Rösch et al. 2022), die sich diesem Thema widmeten, wurde das Thema ebenso im Projekt KI Absicherung behandelt.

1.4.2 Daten für Training und Test erzeugen

Trainings-, Validierungs- und Testdaten sind für die Absicherung von KI-Systemen essentiell. Dabei ist der Einsatz von realen, also mit Hilfe von Testfahrzeugen und entsprechenden Sensoren (Kameras, LiDAR, Radar, usw.) unabdingbar. Die Erfassung und Aufbereitung von realen Daten ist jedoch sehr aufwendig und teuer. Eine zentrale Herausforderung ist, dass neben den eigentlichen Sensordaten des Fahrzeugs auch Referenzdaten, sogenannte Ground Truth oder Labels, erfasst werden müssen. Für viele Aufgaben, z.B. Fußgängererkennung, können diese nur manuell generiert werden und können nicht automatisiert oder durch zusätzliche Sensoren erfasst werden. Dementsprechend gibt es kaum größere Datensätze, die zu Forschungs- und Entwicklungszwecken verwendet werden können. Dazu kommen rechtliche Einschränkungen, die aufgrund des Schutzes der Privatsphäre des Individuums eine Aufnahme im öffentlichen Raum derzeit in Europa nur stark eingeschränkt möglich machen.

Demgegenüber stehen Verfahren der synthetischen Datenerzeugung durch Simulation, die eine Reihe von Vorteilen bieten:

- Die Nutzungsrechte sind nicht grundsätzlich eingeschränkt. Vor allem können Parameter wie z.B. Fahrzeuggeschwindigkeiten oder Szenenkomplexität beliebig variiert werden.
- Im virtuellen Raum können riskante Aktionen beliebig oft ohne Einschränkung nachgestellt werden.
- Synthetische Verfahren können die für Training und Validierung benötigten „Ground truth-Daten“ sehr einfach liefern.



Die Möglichkeit in der Simulation, Fahrsituationen beliebig variieren zu können, macht die synthetische Datenerzeugung besonders geeignet, um systematische Trainings- und Validierungsdaten zu erzeugen.

Um die Realitätsnähe der synthetisch erzeugten Daten sicherzustellen, existiert ebenso der Ansatz, in der Realität aufgenommene Situationen synthetisch nachzubilden vielversprechend.

1.5 Zusammenarbeit mit anderen Stellen

KI Absicherung hat während seiner Laufzeit kontinuierlich daran gearbeitet, Ergebnisse und Konzepte welche die nötige Reife erreicht hatten zu verbreiten und war dazu in Kontakt mit geeigneten Gremien oder anderen Projekten die sich mit dem Thema der Absicherung von KI-Modulen beschäftigen. So wurde das im Projekt entwickelte Konzept zur evidenz-basierten Sicherheitsargumentation für KI-basierte Funktionsmodule in die Definition der ISO PAS 8800 (Safety and Artificial Intelligence) eingebracht und auch in die Fortschreibung des Schwerpunktthemas "Mobilität" der DIN Normungsroadmap KI 2.0 integriert.

Während der Projektlaufzeit wurde Kontakt zu dem BMWK-Projekt Safetrain hergestellt und zum Projekt "Zertifizierte KI", das vom Land Nordrhein-Westfalen gefördert wird. Es gab zusätzlich direkte Kontakte zum BSI, dem einerseits das Projekt und seine Kernergebnisse vorgestellt wurden, und das andererseits - wie auch DIN und ISO - einen Beitrag zur Abschlussveranstaltung beigesteuert hat.

Die in KI Absicherung entwickelte Ontologie wurde mit dem Projekt VV Methoden und dem LI-Schwesterprojekt KI Data Tooling abgeglichen. Auf diese oder vergleichbare Aktivitäten sollte in zukünftigen Projekten oder Standardisierungsaktivitäten auch weiterhin ein Augenmerk gelegt werden um die verschiedenen Ontologien und ODD-Beschreibung zusammenzuführen, z.B. im Rahmen der OpenOntology und OpenODD ASAM-Aktivitäten. Auch sollten die definierten Label- und Metainformationen, welche in der gemeinsamen Spezifikation (E1.2.3 / E4.1.4b) festgehalten wurden anderen Projekten oder der OpenLabel Initiative der ASAM als Input dienen.

Die Zusammenarbeit mit anderen Stellen wurde meist von einzelnen Partnern vorangetrieben, die zum Beispiel auch in den verwandten Projekten mitarbeiten oder die bereits in bestimmten Gremien vertreten waren und auch weiterhin sind. Dieser Umstand wird sicherstellen, dass die Konzepte aus KI Absicherung dort auch weiterhin eingebracht werden und damit den langfristigen Impact des Projektes und seiner Ergebnisse stärken.

Im Rahmen des Projektes hat das DLR im Kern mit den Projektpartnern aus dem AP2.2 zusammengearbeitet. Im Wesentlichen waren dies: Quality Minds GmbH als AP-Leitung für alle organisatorischen Abstimmungen, die Taxonomie und Einbindung der DLR-Arbeiten in das Projekt; BMW Group als TP Leitung für AP-übergreifende Themen; ika für die Generierung der synthetischen Szenen; VW und DFKI für alle AP-internen Arbeiten. Tabelle 1 liefert einen Überblick der Ansprechpartner der einzelnen Projektpartner.

Tabelle 1 – Übersicht der beteiligten Ansprechpartner der Verbundpartner

Verbundpartner	Ansprechpartner
QualityMinds GmbH	Bastian Knerr, Bettina Stühle, Michael Mlynarski, Niels Heller, Marco Hoffmann, Namrata Gurung



Verbundpartner	Ansprechpartner
BMW Group	Thomas Stauner
Institut für Kraftfahrzeuge (ika), RWTH Aachen	Michael Schuldes
Volkswagen Nutzfahrzeuge	Yasin Bayzidi
Deutsches Forschungszentrum für Künstliche Intelligenz GmbH (DFKI)	Andreas Kölsch, Igor Vozniak



2. ERGEBNISSE

2.1 Darstellung der Verwendung der Zuwendung und des erzielten Ergebnisses

Die im folgenden Abschnitt dargestellten Ergebnisse sind alle im Kontext des AP2.2 entstanden, in welchem das DLR in KI Absicherung alleinig aktiv war.

2.1.1 Recherche zu verkehrssituativen Corner Cases

Im Rahmen des E2.2.4 wurden vom DLR die Projektarbeiten mit einer Literaturrecherche zu CC und bestehenden Taxonomien im Projektkontext begonnen. Damit wurde der wissenschaftliche Stand der Technik erfasst, um mit den anschließenden Arbeiten darauf aufzubauen. Aus einer anfänglich thematisch weitgefassten Literaturrecherche wurde sich schließlich in Abstimmung mit den AP-Mitgliedern eine Recherche über CC in Bezug auf Verkehrssituationen, Atypiken, Unfälle und entsprechenden Taxonomien fokussiert. Für die Recherche wurden unterschiedliche Plattformen genutzt: u.a. Science Direct, Researchgate, Google Scholar und Scopus.

Die Recherche ergab eine Übersicht über die Definition von CCs und dazugehörigen Taxonomien in Bezug auf bestimmte Szenarien während des automatisierten Fahrens. Dazu gehört auch die Entwicklung der Automatisierungsstufen, weil pro Stufe unterschiedliche Anforderungen an das autom. Fahren gestellt werden. Hierzu gehört auch die Bewältigung von bestimmten Fahraufgaben, welche automatisiert oder nicht automatisiert erfolgen können. Die zweite große Erkenntnis in der Recherche bezieht sich auf einen gewonnenen Überblick über das Verhalten von Verkehrsteilnehmern. In der Recherche wurde eine Auflistung identifiziert, die das „nicht richtige“ Verhalten und die Aggressivität im Straßenverkehr widerspiegelt. Im Kontext von Verkehrsthemen wurden einzelne relevante Veröffentlichungen identifiziert.

Im Rahmen der erweiterten Literaturrecherche wurden zwei neue Themengebiete aufgetan, die für eine weitere Recherche aus Projektperspektive lohnenswert sind. Auf der einen Seite ist es die Sichtweise einer KI auf die Verkehrssituationen und andererseits ist es die Sicht bzw. das Verhalten eines Fußgängers im Verkehr.

Für den Einbezug der KI-Sicht in die Verkehrssituationen wurde bei der Recherche die Interaktion von automatisierten Fahrzeugen und Fußgängern betrachtet. Diese Interaktionen beziehen sich auf z.B. die Fußgängerüberwege oder den Kreuzungsbereich. Eine weitere Erkenntnis der Recherche war die Ermittlung von Unfällen mit automatisierten Fahrzeugen. Die dort vorherrschenden Situationen sind nachfolgend aufgelistet: Fahren in den Gegenverkehr, Fahrzeug „übersieht“ den kreuzenden oder querstehenden Verkehr (oftmals LKW oder große Fahrzeuge mit weißen Seitenflächen), Spuren teilen sich auf und das Fahrzeug fährt falsch weiter, Fußgänger auf der Landstraße „übersehen“.

Im Kontext der DLR-eigenen Forschungskreuzung, die Teil der Anwendungsplattform Intelligente Mobilität (AIM) ist, wurden Beispiele für CCs erarbeitet, welche das atypische Verhalten oder Regelverstöße der Verkehrsteilnehmer widerspiegeln. Diese CCs wurden in einer Taxonomie hinsichtlich zusammengefasst.

2.1.2 Beitrag zur Corner Case Taxonomie

Im E2.2.5 hat das DLR einen Beitrag zur Corner Case Taxonomie geleistet, indem eine Erweiterung der Taxonomie um verkehrssituative CCs vorgeschlagen wurde. Der in der



Abbildung 2 dargestellte Teilbereich der Taxonomie wurde nochmals in „Rule Violation“ und „Atypical behavior“ untergliedert, damit die verkehrssituativen CCs nochmal besser unterschieden werden können.

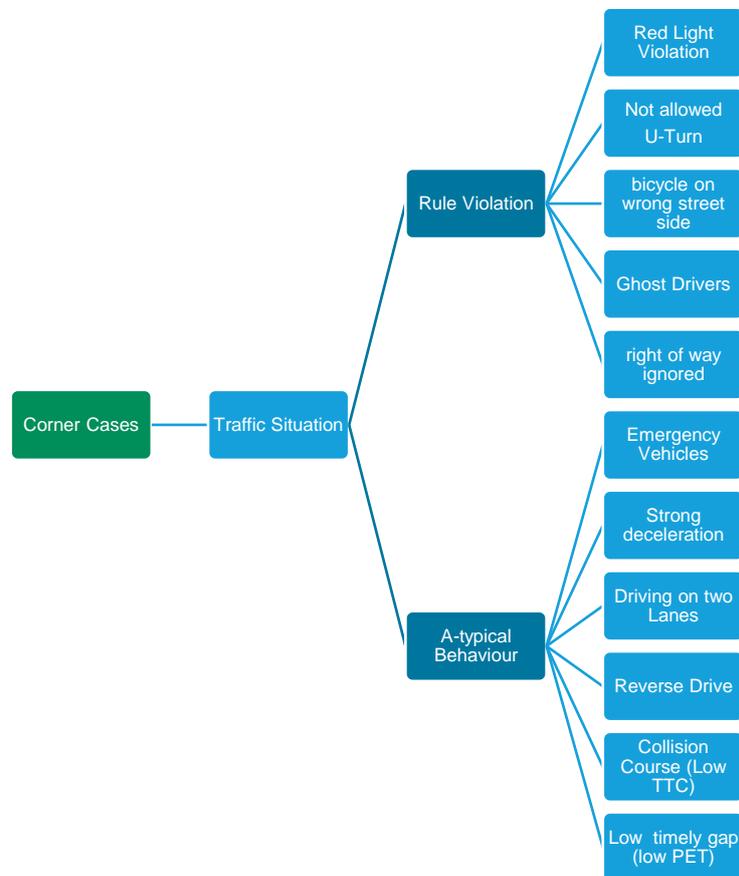


Abbildung 2: Corner Cases Taxonomie aus verkehrssituativer Perspektive

2.1.3 Realistischer Anteil und Verteilung von VRU an einer urbanen Kreuzung

Es wurde festgestellt, dass die im Projekt erzeugten synthetischen Datensätze weniger Fußgänger beinhalten als reale Vergleichsdatsätze (z.B. der Kitty Datensatz). Um eine Aussage treffen zu können, wie viele Fußgänger/Fahrradfahrer an einer urbanen Kreuzung in welchem Bereich zu erwarten sind, wurden die realen Trajektorien des DLR von der AIM Forschungskreuzung in Braunschweig ausgewertet. Für die Erstellung von CC-Datensätzen war die Information über die normale Verteilung von Fußgängern/Fahrradfahrern ebenso relevant. Nur indem bekannt ist, welche Verteilungen normal sind, können unnormale Verteilungen für die Corner Case Datensätze identifiziert werden.

In einem ersten Schritt wurde der generelle Anteil von Fußgängern/Fahrradfahrern an allen Objekten des Datensatzes berechnet. Im untersuchten Datensatz schwankte die gesamte Anzahl der Verkehrsteilnehmer von ca. 200.000-330.000 Verkehrsteilnehmern pro Woche. Der Anteil der Fahrradfahrer lag dabei zwischen 6,1-6,5%, der Anteil der Fußgänger zwischen 5,2-5,8%.

Des Weiteren wurde ein Tag des Datensatzes detaillierter analysiert, indem die AIM Forschungskreuzung in ein Raster aus 0,5x0,5 Meter großen Zellen eingeteilt und die Anzahl der unterschiedlichen Verkehrsteilnehmer pro Zelle analysiert. Somit konnte eine Verteilung

über den gesamten Bereich der Kreuzung aufgestellt und Bereiche identifiziert werden, in denen sich Fußgänger/Fahrradfahrer seltener befinden als in anderen.

Neben der absoluten Anzahl der pro Zeiteinheit detektierten Fußgänger/Fahrradfahrer in einem bestimmten Bereich, wurde auch der prozentuale Anteil der Fußgänger/Fahrradfahrer an allen Objekten, die in einem bestimmten Bereich erkannt wurden, berechnet.

Die Ergebnisse dieser Auswertung wurden in der Anforderungsdefinition für die Tranchen der synthetischen Datenproduktion durch Mackevision für das Konsortium berücksichtigt.

Ein Ergebnis der Auswertung wird in Abbildung 3 visualisiert. Auf dem Satellitenbild sind die Aufenthaltsorte der Fußgänger entsprechend des sensorischen Erfassungsbereiches dargestellt. Stark frequentierte Bereiche sind entsprechend dunkler eingefärbt.

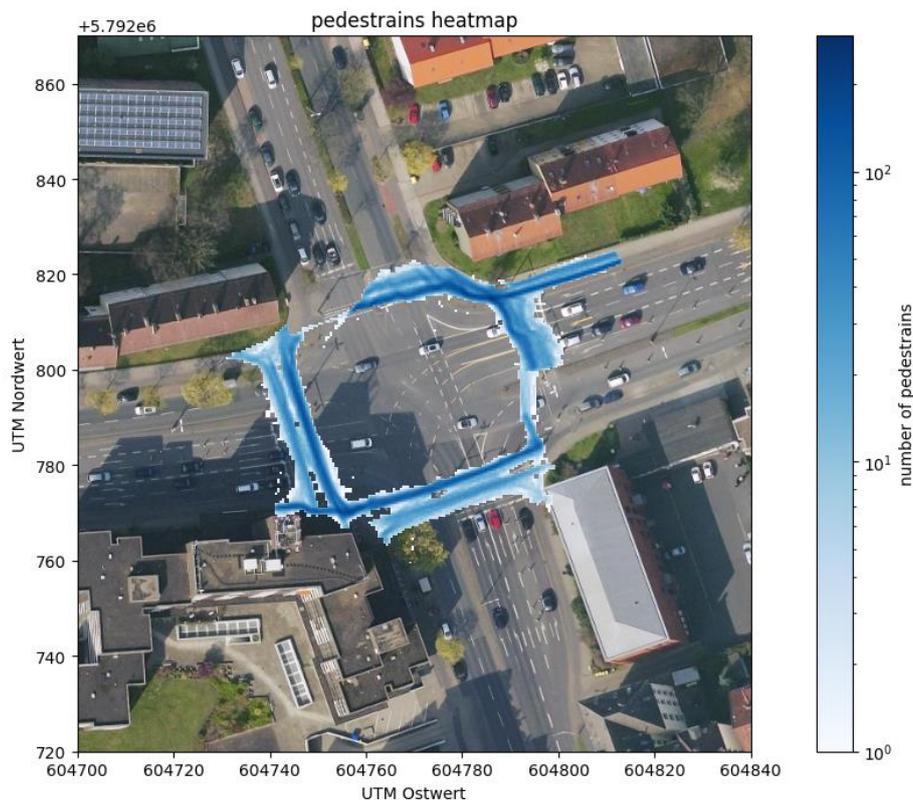


Abbildung 3: Verteilung und Anzahl der Fußgänger auf der AIM Forschungskreuzung

2.1.4 Detektion kritischer verkehrssituativer Corner Cases in Trajektoriendaten

Um einen Beitrag für einen CC Datensatz zu liefern und die Methodenentwicklung zur Detektion von CCs voranzutreiben, wurden die DLR-internen Trajektoriendaten mit der Fragestellung ausgewertet, inwieweit Corner Cases in den Daten vorliegen bzw. identifiziert werden können. Da die Expertise des DLR vor allem in der Analyse des Verkehrsgeschehens liegt, wurde das Thema Corner Cases vom DLR aus einer verkehrssituativen Perspektive betrachtet. Als erster Beitrag wurde eine Methodik erarbeitet, mit der untypische Anzahlen von Verkehrsobjekten (zum Beispiel Fußgängern) detektiert werden können.

Anschließend wurde ein bestimmter CC aus der Taxonomie als Untersuchungsgegenstand ausgewählt. Hierzu wurde auf das Ergebnis E2.2.5 zurückgegriffen und der verkehrssituative Corner Case „Not allowed U-Turn“ aus dem Bereich „Rule Violation“ gewählt, weil dieser DLR-seitig bisher nicht untersucht wurde. Der Bezug zur Detektion von Fußgängern wurde



geschaffen, indem die Interaktion zwischen den Fahrzeugen, die den U-Turn durchführen (nachfolgend auch Motorised Road Users, kurz MRU) und den querenden Fußgängern und Radfahrern (nachfolgend auch Vulnerable Road Users, kurz VRU) nach Kritikalität bewertet wurde. Die Bewertung der Kritikalität ist von Interesse, da kritische Situationen relevant für die Absicherung von Fahrfunktionen sind.

2.1.4.1 Vorstellung der Methodik

Als zugrundeliegende Datenbasis für die Anwendung der Methode wurden reale Trajektorien von Verkehrsteilnehmern verwendet, die an der AIM Forschungskreuzung des DLR aufgezeichnet wurden. Auf der Kreuzung besteht ein Wendeverbot für die von Westen in die Kreuzung einfahrenden Verkehrsteilnehmer. Dennoch führen manche Verkehrsteilnehmer an dieser Stelle einen Richtungswechsel durch. Um diesen verkehrssituativen Corner Case in den Trajektorien zu detektieren, wurde folgende Methodik entwickelt und angewandt:

1. Filterung der relevanten Daten
 - 1.1. Trajektorien von U-Turn Manövern im Westen der Kreuzung
 - 1.2. Trajektorien von VRUs, die im Westen der Kreuzung die Furt passieren
2. Berechnung der Post-Encroachment Time (PET) zwischen den MRUs und VRUs
3. Berechnung der Time-To-Collision (TTC) zwischen den MRUs und VRUs
4. Filterung der relevanten Interaktionen anhand eines nutzerdefinierten Schwellenwerts
5. Analyse und Auswahl der relevanten Szenen für einen CC-Datensatz

Im nachfolgenden Abschnitt werden die einzelnen Schritte näher erläutert.

Der erste Schritt wurde mit Hilfe von digitalen optischen Schleifen umgesetzt, die jeweils an der relevanten Ein- und Ausfahrt der Kreuzung platziert wurden. Anschließend wurde überprüft, welche Trajektorien im Datensatz Schnittpunkte mit diesen optischen Schleifen aufweisen. Sollte eine Trajektorie beide optische Schleifen schneiden, kann sie der Route von Westen nach Westen zugeordnet werden.

Nach gleichem Prinzip werden die Trajektorien der VRUs gefiltert, um aus dem Datensatz die Trajektorien der VRUs zu identifizieren, die sich über die Furten im Westen bewegen.

Anschließend erfolgt die Bewertung der Kritikalität zwischen den motorisierten Verkehrsteilnehmern und den VRUs. Zur Quantifizierung der Kritikalität werden sogenannte Surrogate Measures of Safety (SMoS) verwendet. Speziell für den vorliegenden Fall von sich kreuzenden Trajektorien eignet sich die Anwendung der Kennzahl Post-Encroachment Time (PET) in Kombination mit der Time-To-Collision (TTC). Die PET ist definiert als die Zeit zwischen den Momenten, an denen zwei Verkehrsteilnehmer die gleiche Position passieren (Allen et al. 1978). Um Situationen detektieren zu können, in denen die Situation durch das Abbremsen des Fahrzeugs entschärft wird, wird zusätzlich zur PET die TTC über den Verlauf der gesamten Trajektorien berechnet und der minimale TTC-Wert ($\min(\text{TTC})$) als Maß für die Kritikalität verwendet.

Die Methodik wird durch andere Literatur unterstützt. So stellt zum Beispiel Johnsson fest, dass die TTC im Vergleich zur PET zumindest bei Radfahrer-Fahrzeug-Interaktionen ein geeigneteres Surrogatmaß darstellt (Johnsson et al. 2021). Außerdem ergibt Zheng's Validierung unterschiedlicher Maße, dass die Kombination von TTC und PET im Vergleich zu anderen Parametern die höchste Genauigkeit in Bezug auf die Schätzung von Unfällen ermöglicht (Zheng et al. 2019).



Die Berechnung der Kenngrößen basiert im vorliegenden Anwendungsfall auf den Schnittpunkten zwischen den U-Turn-Trajektorien und den VRU-Trajektorien. Demnach wird nach der Identifikation der beiden Trajektoriendatensätze für jede Trajektorie aus dem U-Turn-Datensatz der Schnittpunkt mit allen relevanten Trajektorien aus dem VRU-Datensatz berechnet.

Als relevant werden all diejenigen VRU-Trajektorien erachtet, die frühestens 10 Minuten vor der ersten bzw. 10 Sekunden nach der letzten Detektion des jeweiligen Fahrzeugs aufgezeichnet wurden. Außerdem müssen die Schnittpunkte nicht nur zeitlich, sondern auch räumlich gefiltert werden. Für das untersuchte Szenario sind nämlich nur die Schnittpunkte relevant, die im Bereich der Furten der westlichen Ausfahrt liegen. Alle Schnittpunkte, die im Bereich der Einfahrt in die Kreuzung liegen, sind für die vorliegende Untersuchung nicht relevant und werden daher nicht betrachtet.

Das Ergebnis des vorherigen Schrittes sind alle SMOs-Werte, die aus den Schnittpunkten der Trajektorien berechnet werden konnten. Da vor allem die kritischen Interaktionen erhöhte Relevanz für die Absicherung von Fahrfunktionen aufweisen, werden die SMOs-Werte mit einem benutzerdefinierten Schwellenwert verglichen und gefiltert.

In einem weiteren Schritt können einzelne Szenen aus den detektierten Situationen ausgewählt werden, um die Gesamtsituation auf der Kreuzung einem CC-Datensatz hinzuzufügen. Damit ist die vorgestellte Methodik Grundlage für die Erzeugung von CC Datensets im Rahmen des Ergebnisses E2.2.7.

2.1.4.2 Anwendung der Methodik

Nachdem die Methodik nun theoretisch vorgestellt wurde, werden nachfolgend die Ergebnisse der Anwendung der Methodik auf einen beispielhaften Datensatz vorgestellt. Hierzu wird zunächst der Umfang des Datensatzes erläutert.

Der zu untersuchende Datensatz wurde innerhalb von 2 Wochen (336 Aufnahmestunden) zwischen dem 17. Juni 2019 und 1. Juli 2019 an der AIM Forschungskreuzung des DLR aufgezeichnet. Während dieser Zeitperiode konnten ca. 700.000 Trajektorien von Verkehrsteilnehmern erfasst werden. Die Verteilung der erfassten Verkehrsteilnehmer über die Aufnahmezeit kann der Abbildung 1 entnommen werden. Es lassen sich Tagesspitzen am Morgen und Nachmittag sowie eine geringere Anzahl an Verkehrsteilnehmern am Wochenende erkennen.

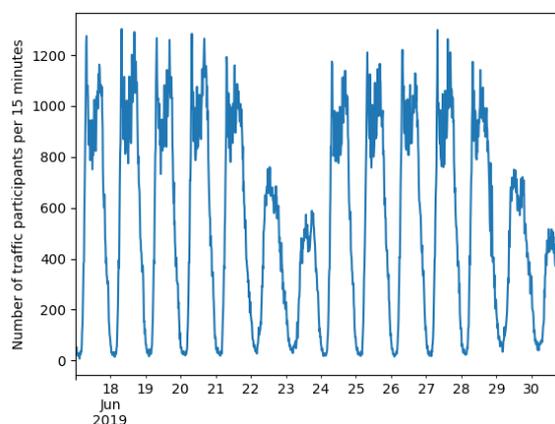


Abbildung 4: Anzahl der Verkehrsteilnehmer pro 15 Minuten über die gesamte Zeitdauer des Datensatzes



Durch Berechnung der Schnittpunkte der Trajektorien mit den optischen Schleifen konnten 408 Trajektorien von motorisierten Verkehrsteilnehmern im untersuchten Datensatz erfasst werden, die den im Westen der Kreuzung verbotenen U-Turn durchgeführt haben. Dazu wurden die digitalen optischen Schleifen jeweils auf der Seite der Fahrradfahrrerfurt platziert, die der Kreuzungsmitte näher liegt. Die Trajektorien und die für die Detektion verwendeten digitalen optischen Schleifen können der Abbildung 5 entnommen werden.

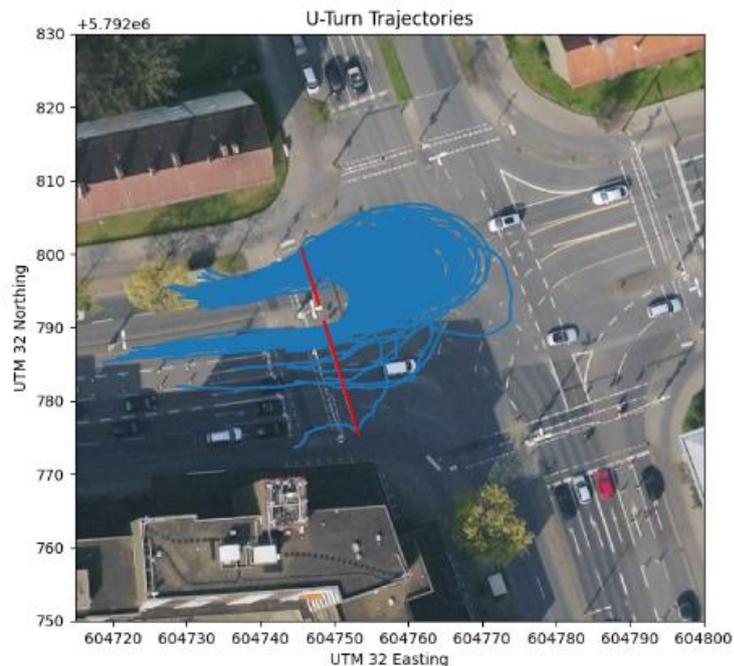


Abbildung 5: Optische Schleifen (rot) und Trajektorien (blau) der motorisierten Verkehrsteilnehmer im gesamten Datensatz, die einen U-Turn im Westen der Kreuzung durchgeführt haben.

Nach gleichem Verfahren wurden die Trajektorien der VRU im Datensatz detektiert. Hierfür wurden die optischen Schleifen an den Übergängen von den abgesenkten Bordsteinen und der Fahrbahn platziert. Die verwendeten optischen Schleifen sowie die Trajektorien der am 30. Juni 2019 erfassten VRUs in den westlichen Furten sind in Abbildung 6 dargestellt.



Abbildung 6: Optische Schleifen (rot) und Trajektorien (blau) der nicht-motorisierten Verkehrsteilnehmer, die die Furten im Westen der Kreuzung an einem Tag des Datensatzes (30. Juni 2019) passiert haben.

Auf Basis der beiden Trajektorien Datensätze konnten 8.982 SMOs Werte für die jeweiligen Trajektorien berechnet werden. Pro U-Turn Trajektorie wurden demnach ca. 22 SMOs PET Werte berechnet. Um aus den 8.982 SMOs-Werten die relevanten Interaktionen festzustellen, wird vom Benutzer der Methodik ein Schwellenwert festgelegt. Im vorliegenden Fall wird das Ergebnis für einen Schwellenwert von einer absoluten PET von unter 2 Sekunden vorgestellt. Damit verbleiben 7 Interaktionen in dem untersuchten Datensatz, deren Daten in Tabelle 1 dargestellt sind. In den ersten zwei Spalten der Tabelle sind die von der Erfassungstechnik festgelegten IDs der Verkehrsteilnehmer angegeben. Die dritte Spalte enthält den PET-Wert der Interaktion. Ein positiver PET-Wert bedeutet, dass das Fahrzeug den Schnittpunkt mit der VRU-Trajektorie als erstes erreicht, ein negativer PET-Wert bedeutet, dass der VRU den Schnittpunkt als erstes erreicht. In der vierten Spalte wird die minimale TTC der Situation dargestellt. In der Spalte Zeitstempel wird der Zeitpunkt des Schnittpunkts angegeben.

Die in Tabelle 2 dargestellten detektierten CC wurden zu einem Datensatz zusammengefügt.

Tabelle 2: PET und minimale TTC für Werte mit einer PET zwischen -2 und 2 Sekunden

U-Turn ID	VRU ID	PET [s]	min(TTC) [s]	Zeitstempel PET
2929770	11249818	-1,64	1,34	2019-06-18 17:38:38.59
3034649	11670342	-1,44	0,69	2019-06-19 18:21:50.59
3290226	12602936	-2	2,07	2019-06-22 14:41:42.07
3681781	14072480	1,68	1,52	2019-06-27 07:29:03.41
3782857	14447281	-1,8	2,02	2019-06-28 06:40:15.73
3782857	14447546	-1,64	2,66	2019-06-28 06:40:16.13
3804977	14512859	-1,88	2,95	2019-06-28 10:04:14.11

In der vorliegenden Untersuchung weißt die Situation mit der geringsten PET auch die geringste TTC auf (siehe Zeile 2 in Tabelle 2). Damit wird diese Situation auch unter Kombination beider Maße als kritischste Situation bewertet.



Für die Absicherung von Fahrfunktionen sind vor allem die Situationen mit einer geringen negativen PET relevant. In diesen Situationen erreicht der VRU den Schnittpunkt als erstes und befindet sich zu diesem Zeitpunkt auf der zukünftigen Trajektorie des Fahrzeuges. Die Situation mit dem kritischsten negativen PET Wert von -1,44 Sekunden wurde beispielhaft aus dem Datensatz extrahiert und die Positionsdaten der in dieser Situation erfassten Verkehrsteilnehmer in Abbildung 7 dargestellt.

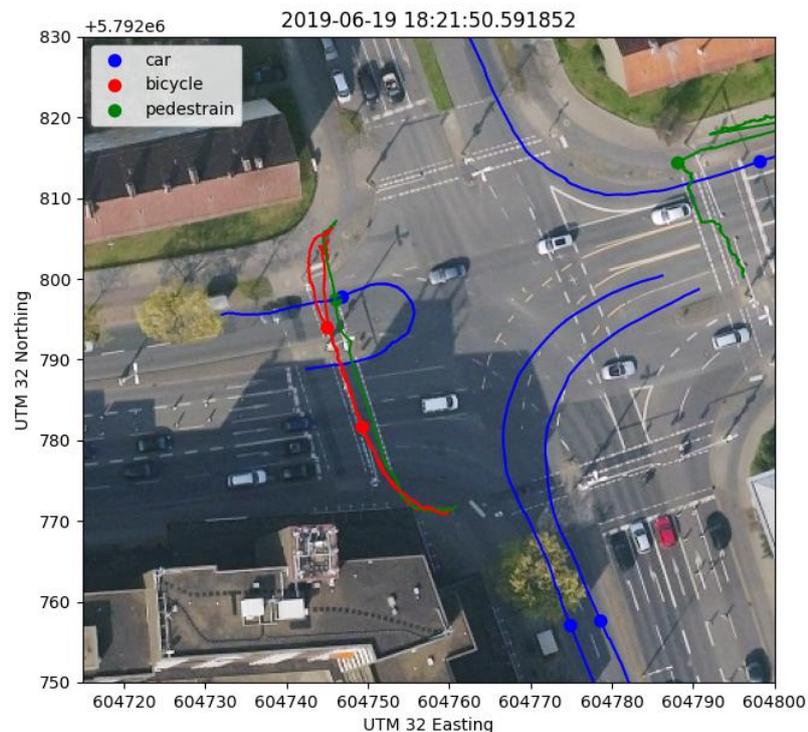


Abbildung 7: Situation mit der kritischsten negativen PET. Die Kreise geben die Position eines Verkehrsteilnehmers zur ausgewählten Situation an. Zur Einordnung des Bewegungsverlaufs wurden ebenso die gesamten Trajektorien der Verkehrsteilnehmer als Linien dargestellt.

2.1.4.3 Untersuchung der Generalisierbarkeit der Methode

Außerdem wurde getestet, ob die Methode von der Topologie der AIM Forschungskreuzung abhängig ist oder verallgemeinert angewandt werden kann. Hierzu wurde die Methode auf die U-Turns im Süden der AIM Forschungskreuzung angewandt. Die kritischste Situation ist in Abbildung 8 dargestellt. Diese wies eine Post-Encroachment Time (PET) von -1,7 Sekunden auf. Das heißt, dass der Fußgänger 1,7 Sekunden nachdem sich das Fahrzeug an einer Position befand, dieselbe Position erreichte. Normalerweise unterbindet die Schaltung der Lichtsignalanlage die Begegnung zwischen den beiden Verkehrsteilnehmern. Da das Fahrzeug, das den U-Turn ausgeführt, eine längere Zeit auf der Kreuzung warten musste, um Fahrzeuge von Westen nach Süden passieren zu lassen, kam es zu dieser Interaktion.



Abbildung 8: Visualisierung der kritischsten Interaktion im Süden der Kreuzung. Der Fußgänger (rote Trajektorie) beginnt mit dem Überqueren der Furt, während das Fahrzeug, das den U-Turn ausführt, die Furt im selben Zeitpunkt schneidet.

2.1.5 Synthetische Nachbildung der kritischsten Szene

Die Daten zu den verkehrssituativen Corner Cases, die mittels der im E2.2.4 erarbeiteten Methodik detektiert werden konnten, lagen bisher nur in Form von Trajektorien DLR-intern vor. Unter Einbringung eigener Ansätze wurde aus den Trajektorien der dynamischen Objekte die kritischste Situation beispielhaft von der DLR-Kreuzung auf die Leonberg-Kreuzung übertragen. Damit konnten die Daten in synthetische Szenen übersetzt und für das Projekt generiert werden. Gemeinsam mit Michael Schuldes vom Projektpartner (ika) wurden die zu erzeugenden Variationen in Bezug auf Objektposition, -pose und -asset sowie Beleuchtung, Sonnenstand und Wetterbedingungen wie Pfützensgröße oder Nebeldichte definiert und darauf geachtet, dass eine Variation enthalten ist, die die realen Umgebungsbedingungen der aufgezeichneten Szene so realitätsnah wie möglich abbildet. Insgesamt wurden 107 Variationen erstellt, welche nun in Tranche 7 Sequenz 96 Frames 5464-5571 vorliegen. Damit wurde gezeigt, wie ein verkehrssituativer Corner Case synthetisch nachgestellt werden kann. Damit wurde ein Beitrag zum E2.2.7 geleistet.

Eine beispielhafte Visualisierung der Übertragung der realen Szene in synthetische Daten ist in Abbildung 9 dargestellt.

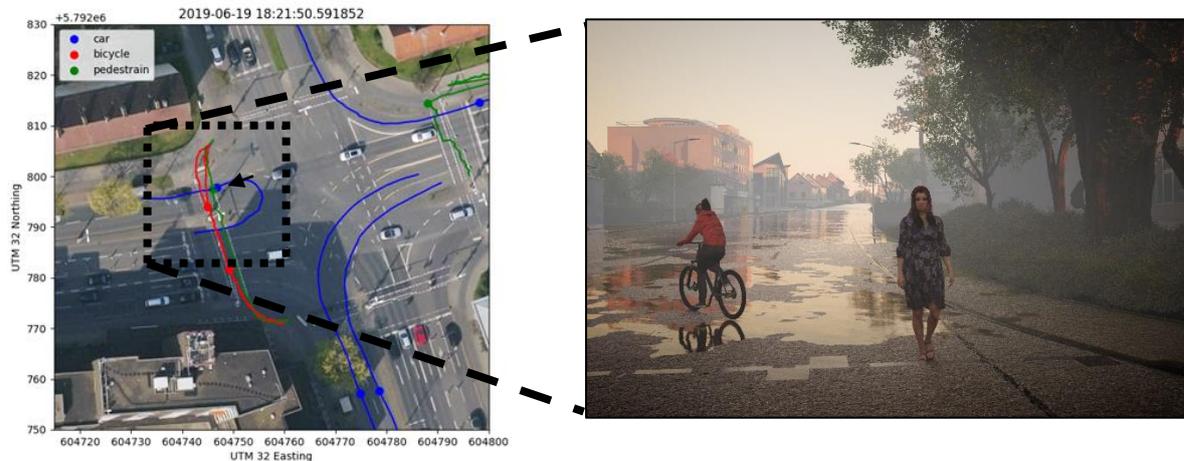


Abbildung 9: Schematische Darstellung der Konvertierung der Szene von den Realdaten der Forschungskreuzung des DLR (Im rechten Bild wird eine Variation der synthetisierten Szene aus Fahrzeugperspektive visualisiert.)

2.2 Wichtigste Positionen des zahlenmäßigen Nachweises

Der Großteil der Förderung des DLR wurde für Personalmittel (Pos. 0837) in Höhe von ca. 136 t€ verwendet, welches ca. 10 Personenmonaten entspricht. Es wurde aufgrund der Corona-Pandemie relativ sehr wenig gereist, so dass nur ca. 2t€ für Reisen (Pos. 0838) verwendet worden sind. Weiterhin wurden gemeinsame Unteraufträge (GUA) 1 und 2 für ein Projektbüro durchgeführt. Hier sind unter Pos. 0850 ca. 18 t€ angefallen. Das DLR hat die gesamte Förderung von ca. 156 t€ nutzen können.

2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die Automatisierung von Straßenfahrzeugen unter Anwendung von Methoden der Künstlichen Intelligenz stellt sowohl in der technischen Realisierung wie auch in dem notwendigen Nachweis der hinreichenden Sicherheit eine große Herausforderung dar. Zum Problem der Absicherung sollte KI Absicherung am Beispiel der Erkennung von Fußgängern eine praktikablen Lösungsansatz entwickeln und demonstrieren.

Dies ist für die deutsche Automobilindustrie – OEMs und Zulieferer – eine bedeutende Zukunftsthematik, zu deren Behandlung Forschungsgrundlagen auf vielen Gebieten fehlten. So ist auch die Einbeziehung des Instituts für Verkehrssystemtechnik des DLR als eines Partners der angewandten Forschung motiviert; denn das Institut ist auf dem Gebiet breit ausgewiesen und verfügt sowohl über Personal mit hochrelevanten Kompetenzen wie auch über Forschungsinfrastrukturen, die zum Projekterfolg wesentlich beitragen konnten. Im AP2.2 konnte aus der Perspektive der verkehrssituativen corner cases ein sehr lohnenswerter zu sensorseitigen corner cases komplementärer Ansatz eingebracht werden. Gemessen an der geringen fokussierten Projektbeteiligung des DLR im Umfang von ca. 10PM in AP2.2 wurden siehe Abschnitt 2.1 wirksame Beiträge zu den Ergebnissen und insbesondere dem gemeinsamen KI Absicherungs Datensatz geleistet.



2.4 Voraussichtlicher Nutzen – Verwertbarkeit des Ergebnisses im Sinne des Verwertungsplanes

Die im Projektantrag benannten Aussichten im Kontext des Verwertungsplanes haben weiter Bestand. Die Ergebnisse des Projektes KI Absicherung können wissenschaftlich und auch technisch sehr gut genutzt werden. Hierbei kann das DLR aufgrund seiner Rolle eines Großforschungszentrums seine weitreichenden Erfahrungen und Möglichkeiten im Bereich der anwendungsnahen Forschung an deutsche Unternehmen und Institutionen weitergeben z.B. in weiteren Förderprojekten oder Direktauftragungen aus der Industrie. Mit der Teilnahme am Vorhaben KI Absicherung legte das DLR den fachlichen Grundstein für die zukünftige erfolgreiche Mitarbeit an weiteren Projekten im Bereich der anwendungsnahen KI-Forschung für den Bereich des automatisierten Fahrens. Als Beispiel lässt sich hier die Mitwirkung an weiteren Projekten der KI-Familie (wie z.B. Data Tooling) sowie im Kontext GAIA-X (z.B. GAIA-X4PLC-AAD) nennen. In letzterem werden o.g. Methoden zur Extraktion verkehrssituativer Corner Cases im Kontext der Autobahn angewendet und weiterentwickelt. Die durch das DLR in KI Absicherung entwickelten Methoden sind weiterhin Grundlage für ein laufendes Promotionsprojekt und werden im Kontext des Projektes KI Data Tooling weiterentwickelt.

2.5 Bekannter Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Es wurde während der Projektlaufzeit kein wesentlicher Fortschritt bei anderen Vorhaben identifiziert, der signifikante Auswirkungen auf die Arbeiten des DLR im Projekt KI Absicherung hatte.

2.6 Erfolgte und geplante Veröffentlichungen

Wesentliche erzielte Resultate aus dem Abschnitt 2.1 wurden in einer Kurzfassung zusammengefasst und auf der Konferenz „International Co-operation on Theories and Concepts in Traffic safety“ (ICTCT) eingereicht (Schick Tanz und Gimm 2022). Der Beitrag wurde vom Komitee der Konferenz als Poster-Präsentation angenommen. Das Poster wurde auf der Konferenz Ende Oktober 2022 vorgestellt.

Es ist geplant diese Arbeiten in einer Fachzeitschrift mit dem Namen „European Transport Research Review“ (ETTR) zu veröffentlichen. Im Kontext der oben genannten Konferenz ist eine Ausgabe mit dem Titel „Challenges and methods in road safety improvement: beyond the low-hanging fruit“ vorgesehen. Ein Manuskript wird zum 31.01.2023 eingereicht.

Weiterhin ist es geplant einen Datensatz aus KI-Absicherung heraus zu veröffentlichen. Dieser beinhaltet wesentliche synthetische Daten, die z.B. im Kontext Fußgängererkennung als gelabelte Ground Truth genutzt werden können. Das DLR engagiert sich hier den Datensatz mit eigener IT-Infrastruktur zu hosten und ist in Gesprächen zu einer notwendigen Lizenzierung involviert. Die Aktivität wird aus dem sog. „TPX“ heraus gestützt, welches über KI Data Tooling in TP4 erfolgt und zur Vernetzung der Projekte der KI-Projektfamilie bzw. anderer wesentlicher Projekte beiträgt.



3. REFERENZEN

Literaturverzeichnis

- Allen, Brian L.; Shin, B. Tom; Cooper, Peter J. (1978): ANALYSIS OF TRAFFIC CONFLICTS AND COLLISIONS. In: Transportation Research Record.
- Bogdoll, Daniel; Breitenstein, Jasmin; Heidecker, Florian; Bieshaar, Maarten; Sick, Bernhard; Fingscheidt, Tim; Zollner, J. Marius (2021): Description of Corner Cases in Automated Driving: Goals and Challenges, S. 1023–1028. DOI: 10.1109/ICCVW54120.2021.00119.
- Breitenstein, Jasmin; Termohlen, Jan-Aike; Lipinski, Daniel; Fingscheidt, Tim (2020): Systematization of Corner Cases for Visual Perception in Automated Driving. In: 2020 IEEE Intelligent Vehicles Symposium (IV). 2020 IEEE Intelligent Vehicles Symposium (IV). Las Vegas, NV, USA, 10/19/2020 - 11/13/2020. Institute of Electrical and Electronics Engineers. Piscataway, NJ: IEEE, S. 1257–1264.
- Breitenstein, Jasmin; Termöhlen, Jan-Aike; Lipinski, Daniel; Fingscheidt, Tim (2021): Corner Cases for Visual Perception in Automated Driving: Some Guidance on Detection Approaches. Online verfügbar unter <http://arxiv.org/pdf/2102.05897v1>.
- Heidecker, Florian; Breitenstein, Jasmin; Rosch, Kevin; Lohdefink, Jonas; Bieshaar, Maarten; Stiller, Christoph et al. (2021): An Application-Driven Conceptualization of Corner Cases for Perception in Highly Automated Driving 12, S. 644–651. DOI: 10.1109/IV48863.2021.9575933.
- Johnsson, Carl; Laureshyn, Aliaksei; Dágostino, Carmelo (2021): Validation of surrogate measures of safety with a focus on bicyclist-motor vehicle interactions. In: *Accident; analysis and prevention* 153, S. 106037. DOI: 10.1016/j.aap.2021.106037.
- Rösch, Kevin; Heidecker, Florian; Truetsch, Julian; Kowol, Kamil; Schicktanz, Clemens; Bieshaar, Maarten et al. (2022): Space, Time, and Interaction: A Taxonomy of Corner Cases in Trajectory Datasets for Automated Driving: arXiv, 2022. Online verfügbar unter <https://arxiv.org/pdf/2210.08885>.
- Schicktanz, Clemens; Gimm, Kay (2022): Detection and Analysis of Critical Interactions in Illegal U-turns at an Urban Intersection. International Co-operation on Theories and Concepts in Traffic safety (ICTCT).
- Zheng, Lai; Sayed, Tarek; Essa, Mohamed (2019): Validating the bivariate extreme value modeling approach for road safety estimation with different traffic conflict indicators. In: *Accident; analysis and prevention* 123, S. 314–323. DOI: 10.1016/j.aap.2018.12.007.

Berichtsblatt

1. ISBN oder ISSN -	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel KI Absicherung – Schlussbericht	
4. Autor(en) [Name(n), Vorname(n)] Clemens Schickkanz Kay Gimm	5. Abschlussdatum des Vorhabens Juni 2022
	6. Veröffentlichungsdatum November 2022
	7. Form der Publikation Abschlussbericht
8. Durchführende Institution(en) (Name, Adresse) Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR) Institut für Verkehrssystemtechnik Lilienthalplatz 7 38108 Braunschweig	9. Ber. Nr. Durchführende Institution -
	10. Förderkennzeichen 19A19005V
	11. Seitenzahl 24
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 11019 Berlin	13. Literaturangaben 9
	14. Tabellen 2
	15. Abbildungen 9
16. Zusätzliche Angaben -	
17. Vorgelegt bei (Titel, Ort, Datum) -	
18. Kurzfassung Das Projekt KI Absicherung hat zum Ziel, die Sicherheit von KI-basierten Funktionsmodulen für das hochautomatisierte Fahren nachweisbar zu machen. Dafür wird an einer allgemeinen Absicherungsstrategie für KI-Funktionen gearbeitet. Diese soll schlussendlich als Industriekonsenses gelten und in Standardisierungsgremien eingebracht werden. Das DLR hat sich dabei im Arbeitspaket AP2.2 „Corner Cases“ des Teilprojekts TP2 „Synthetische Daten“ engagiert. Im Rahmen des TP2 wird eine Werkzeugkette zur Produktion von synthetischen Daten aufgebaut, mit denen KI-Module trainiert und getestet werden können. Ziel ist es, einen prototypischen Datensatz zu entwickeln, der verwendet werden kann, um die Eignung synthetischer Daten als Ersatz für Realdaten zu bewerten. Speziell bestand für das DLR die Aufgabe, im E2.2.2 Modelle und Daten inkl. der Ideen für Corner Cases mit eigenen Ansätzen und datenbasierten Experimenten zu Trajektorien von dynamischen Objekten einzubringen. Die Darstellung der Ergebnisse dieser Arbeiten ist Gegenstand des Abschlussberichts.	
19. Schlagwörter Automatisiertes und vernetztes Fahren, Künstliche Intelligenz, Corner Cases, Trajektorien, Verkehrskonflikte, Verkehrssituation	
20. Verlag -	21. Preis -

Document Control Sheet

1. ISBN or ISSN -	2. type of document (e.g. report, publication) Final report	
3. title KI Absicherung – Schlussbericht		
4. author(s) (family name, first name(s)) Clemens Schick Tanz Kay Gimm	5. end of project June 2022	
	6. publication date November 2022	
	7. form of publication final report	
8. performing organization(s) (name, address) Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR) Institut für Verkehrssystemtechnik Lilienthalplatz 7 38108 Braunschweig	9. originator's report no. -	
	10. reference no. 19A19005V	
	11. no. of pages 24	
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 11019 Berlin	13. no. of references 9	
	14. no. of tables 2	
	15. no. of figures 9	
16. supplementary notes -		
17. presented at (title, place, date) -		
18. abstract The aim of the project KI Absicherung is to make the safety of AI-based function modules for highly automated driving verifiable. A general safeguarding strategy for AI functions is being developed. Finally, this should be regarded as an industry consensus and introduced in standardization committees. The DLR was involved in the task AP2.2 "Corner Cases" of the sub-project TP2 "Synthetic Data". As part of TP2, a tool chain for the production of synthetic data is being set up with which AI modules can be trained and tested. The aim is to develop a prototypical data set that can be used to evaluate the suitability of synthetic data as a substitute for real data. In particular, DLR had the task of introducing models and data in E2.2.2, including ideas for corner cases with its own approaches and data-based experiments on trajectory data of dynamic objects. The presentation of the results of this work is the subject of the final report.		
19. keywords Automated and connected driving, artificial intelligence, corner cases, trajectories, traffic conflicts, traffic situation		
20. publisher -	21. price -	