Abschlussbericht zum Projekt

Artificial Intelligence enhancing vehicle vision in low visibility conditions (AI-SEE)

Teil II - Eingehende Darstellung

Technische Hochschule Ingolstadt

Zuwendungsempfänger:	Technische Hochschule Ingolstadt Forschungsförderung, -transfer und –controlling (FORTEC) Esplanade 10 85049 Ingolstadt
Projektpartner:	Mercedes Benz AG
Förderkennzeichen:	16ME0345
Projektleitung:	Prof. Dr. Werner Huber 0841/9348-2523 Werner.Huber@thi.de
Projektlaufzeit:	01.06.2021 – 31.12.2024 (inkl. 7 Monate kostenneutraler Verlängerung)
Berichtszeitraum:	01.06.2021 – 31.12.2024

GEFÖRDERT VOM Bundesministerium für Bildung und Forschung	Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter dem Förderkennzeichen 16ME0345 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.

Inhaltsverzeichnis

1 Einführung **3**
1.1 Aufgabenstellung 3
1.2 Voraussetzungen/Ausgangslage 4
1.2.1 Voraussetzungen, unter denen das Projekt durchgeführt wurde . 4
1.2.2 Wissenschaftlicher und technischer Stand, an den angeknüpft wurde 6
1.3 Planung und Ablauf des Vorhabens 8
1.3.1 Teilprojekt 1: Entwicklung eines KI-basierten Modells zur Simulation von Witterungseffekten 8
1.3.2 Teilprojekt 2: Entwicklung einer Vorrichtung zur Erzeugung von Gischt 11
1.3.3 Teilprojekt 3: Validierung und Verbesserung der Umfeldsensorik . 13

2 Eingehende Darstellung **15**
2.1 Soll-Ist-Vergleich der geplanten und erzielten Ergebnisse sowie der eingesetzten Mittel 15
2.1.1 Teilprojekt 1: Entwicklung eines KI-basierten Modells zur Simulation von Witterungseffekten 15
2.1.2 Teilprojekt 2: Entwicklung einer Vorrichtung zur Erzeugung von Gischt 24
2.1.3 Teilprojekt 3: Validierung und Verbesserung der Umfeldsensorik . 35
2.2 Erläuterung der wichtigsten Positionen im zahlenmäßigen Nachweis . . 43
2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit 44
2.4 Voraussichtlicher Nutzen und Verwertbarkeit des Ergebnisses (Fortschreibung des Verwertungsplanes) 44
2.4.1 ANSYS 44
2.4.2 Fifty2 44
2.4.3 THI 44
2.5 Fortschritte auf dem Gebiet des Vorhabens bei anderen Stellen während der Durchführung 45
2.6 Geplante und erfolgte Veröffentlichungen im Rahmen des Vorhabens . . 45
2.6.1 Liste der im Projektzeitraum erfolgten Abschlussarbeiten 46
2.6.2 Liste der im Projektzeitraum erfolgten Studentenprojekte 47
2.6.3 Liste der im Projektzeitraum erfolgten Vorträge 47

3 Kurzfassung/Berichtsblatt **47**

4 Erfolgskontrollbericht **47**

1. Einführung

1.1 Aufgabenstellung

Das Projekt AI-SEE verfolgt das Ziel, eine hochentwickelte All-Wetter-Sensor-Suite für automatisiertes Fahren zu entwickeln. Diese soll Fahrten unter sämtlichen Sichtbedingungen ermöglichen und bis 2030 in SAE-Level-4-Fahrzeuge integriert werden können. Im Mittelpunkt steht die Verbesserung der Sensorwahrnehmung bei gleichzeitiger Reduzierung der Kosten. Die im Projekt erprobten neuartigen Umfeldsensoren sollen kurzfristig ADAS-Funktionen (Advanced Driver Assistance Systems) optimieren und langfristig den sicheren Betrieb automatisierter Fahrzeuge bei allen Witterungsverhältnissen ermöglichen.
Die Automobilbranche befindet sich in einem tiefgreifenden Wandel, getrieben durch technologische Innovationen und gesellschaftliche Veränderungen. Die Nachfrage nach mehr Autonomie und Sicherheit im Verkehr steigt stetig, doch es gibt noch erhebliche technologische Herausforderungen auf dem Weg zum vollständig automatisierten Fahren. Eine der größten Hürden ist die zuverlässige Fahrzeugsteuerung bei schlechten Sichtverhältnissen. Trotz intensiver Forschung und Entwicklung scheitern selbst die fortschrittlichsten Prototypen noch an extremen Witterungsbedingungen wie starkem Regen oder Schnee. Um diese Herausforderungen zu überwinden, bedarf es eines neuartigen Wahrnehmungskonzepts mit hoher Robustheit gegenüber widrigen Umweltbedingungen. Das übergeordnete Ziel des Projekts ist daher die Entwicklung einer zuverlässigen Sensor-Suite, die automatisiertes Fahren unter allen Wetterbedingungen ermöglicht.
Um dieses Ziel zu erreichen, arbeiten Industriepartner, Hochschulen und Forschungseinrichtungen eng zusammen. Die gebündelte Innovationskraft dieser Akteure wird genutzt, um neue Sensortechnologien zu entwickeln, die Datenerfassung zu optimieren sowie KI-gestützte Simulationen und Signalverarbeitung weiter voranzutreiben. Das im Projekt erworbene Wissen fließt direkt in die Produktentwicklung, Optimierung bestehender Technologien und zukünftige Forschungsprojekte ein und trägt so zur Weiterentwicklung der gesamten Branche bei.
Die Entwicklung einer zuverlässigen All-Wetter-Sensor-Suite würde Europas führende Position im Bereich Sensortechnologie weiter stärken. Angesichts eines rasant wachsenden Marktes für Sensoren im automatisierten Fahren könnte ein standardisiertes, leistungsfähiges Sensorsystem zum entscheidenden Erfolgsfaktor für diese Technologie werden. Durch eine einheitliche Sensorlösung würden bestehende Unsicherheiten bei der Auswahl geeigneter Systeme entfallen, während Skaleneffekte in der Produktion die Kosten erheblich senken könnten.
Die Technische Hochschule Ingolstadt hat im Rahmen des Projekts insbesondere die Absicherung der Sensoren bei schwierigen Sichtverhältnissen untersucht. Der Fokus

liegt dabei auf der Simulation und Validierung von Schlechtwetter-Daten – sowohl in realen Testszenarien als auch in virtuellen Umgebungen.
Für die Realisierung dieses Projekts sind die Forschungsaktivitäten in drei Teilprojekte untergliedert, die sich an den jeweiligen Zielen orientieren:

1. **Teilprojekt 1:** Entwicklung eines KI-basierten Modells zur Simulation von Witterungseffekten
2. **Teilprojekt 2:** Entwicklung einer Vorrichtung zur Erzeugung von Gischt
3. **Teilprojekt 3:** Validierung und Verbesserung der Umfeldsensorik

Auf die einzelnen Teilprojekte wird im weiteren Text genauer eingegangen.

1.2 Voraussetzungen/Ausgangslage

1.2.1 Voraussetzungen, unter denen das Projekt durchgeführt wurde

Entwicklung eines KI-basierten Modells zur Simulation von Witterungseffekten

Das Projekt AI-SEE umfasst die Entwicklung, Erprobung und Validierung KI-basierter Modelle zur Simulation realer Witterungseffekte auf Kamerabildern. Zu Beginn des Projekts war das Wissen in diesem Bereich noch begrenzt und basierte weitgehend auf Erkenntnissen aus dem ebenfalls an der Technischen Hochschule Ingolstadt durchgeführten Forschungsprojekt SAFIR. Die Arbeiten begannen mit der grundlegenden Annahme, dass Detektionsalgorithmen unter widrigen Witterungsbedingungen wie Regen, Nebel und Schnee deutlich schlechter arbeiten. Dies liegt unter anderem daran, dass Schlechtwetterdatensätze nur schwer zu erfassen sind und öffentlich verfügbare Datensätze lediglich in begrenztem Umfang existieren.
Vor diesem Hintergrund entstand die Idee, künstlich generierte Trainingsdaten mit simulierten Witterungseffekten in das Training von Detektionsmodellen zu integrieren, um deren Robustheit gegenüber schlechten Sichtbedingungen signifikant zu verbessern. Durch diesen Ansatz kann das Problem der begrenzten Verfügbarkeit realer Schlechtwetterdaten effektiv umgangen werden. Die Integration synthetischer Wettereffekte in das Training ermöglicht eine gezielte Verbesserung der Detektionsleistung und stellt einen wesentlichen Beitrag zur Entwicklung widerstandsfähiger Algorithmen für automatisiertes Fahren dar.
Die durch das Projekt gewonnenen Erkenntnisse helfen nicht nur dabei, die allgemeine Leistungsfähigkeit von Detektionsmodellen zu steigern, sondern tragen auch zur Weiterentwicklung neuer Verfahren zur Datenanreicherung und Simulation bei. Langfristig könnte dieser Ansatz eine Schlüsselrolle bei der Verbesserung von KI-gestützten Wahrnehmungssystemen spielen und die Grundlage für zuverlässigere Sensortechnologien in automatisierten Fahrzeugen schaffen.

Entwicklung einer Vorrichtung zur Erzeugung von Gischt

Wie sich Wetterphänomene wie Regen und Nebel auf Wahrnehmungssensoren wie Kameras und Lidar auswirken, wurde bereits umfassend untersucht. Ein wesentlicher Faktor wurde bisher jedoch nur unzureichend untersucht: Gischt. Gischt entsteht, wenn Wasser von einer nassen Straßenoberfläche durch die Reifen eines fahrenden Fahrzeugs in die Luft getragen wird. Auf Autobahnen wird der Effekt der Gischt durch höhere Fahrzeuggeschwindigkeiten, Überholmanöver und die Anwesenheit schwerer Fahrzeuge wie Lastkraftwagen verstärkt, was zu einer erheblichen Beeinträchtigung der Sensorleistung führen kann. Dieses Problem wird durch den Mangel an verfügbaren Daten über die Beeinträchtigung von Sensoren durch Straßenschmutz noch verschärft.

Einen wichtigen Beitrag zur Untersuchung dieses Phänomens leisteten Shearman et al., die in einer der ersten Studien die Beeinträchtigung von Wahrnehmungssensoren durch Sprühwasser auf der Straße untersuchten [1]. Ihre Experimente auf einer nassen Teststrecke, dass Straßensprühnebel die Sensorleistung bei einem LKW mit einer Geschwindigkeit von 60 km/h um bis zu 20 dB reduzieren kann. Diese Ergebnisse führten zu gesetzlichen Anforderungen für den Einbau von Sprühminderungssystemen an schweren Fahrzeugen [2]. Trotz dieser Fortschritte wurden die kritischen Auswirkungen auf ADAS-Systeme oft übersehen. Die Auswirkungen von Straßenschmutz auf diese Systeme dürfen daher nicht länger vernachlässigt werden. Verschiedene Ansätze wie Feldtests, kontrollierte Laborexperimente und virtuelle Simulationen wurden bereits verwendet, um die Beeinträchtigung von Sensoren durch Straßenschmutz zu messen. Die standardisierte und kosteneffiziente Bewertung von Straßenschmutz stellt jedoch nach wie vor eine große Herausforderung dar.

Ziel dieses Teilprojektes ist die Entwicklung einer Vorrichtung zur ortsunabhängigen Erzeugung von Gischt. Damit soll es der Automobilindustrie ermöglicht werden, automatisierte Fahrfunktionen schnell, reproduzierbar und kontrolliert unter dem Einfluss von Gischt zu testen. Das Gerät wird so kalibriert, dass Sensortests realitätsnah und valide durchgeführt werden können. Darüber hinaus bietet das Gerät die Möglichkeit, die Abhängigkeit der Gischttropfen von unterschiedlichen Fahrzeuggeschwindigkeiten darzustellen. Mit Hilfe des Gischtgenerators kann der Verschmutzungsgrad des Sensors über einen bestimmten Zeitraum und dessen Auswirkungen untersucht werden.

Validierung und Verbesserung der Umfeldsensorik

Verbesserungs- und Detektionenalgorithmen wurden entwickelt und angewendet. Um eine fundierte Bewertung der Sensorleistung zu ermöglichen, war es erforderlich, sowohl simulationsbasierte als auch reale Messverfahren einzusetzen. Diese duale Her-

angehensweise stellte eine wesentliche Voraussetzung für die Validierung der Komponenten dar.
Ein zentraler Forschungsschwerpunkt des Projekts lag in der Untersuchung und Verifizierung der Funktionalität und Leistungsfähigkeit des Radarsensors unter verschiedenen Umweltbedingungen. Insbesondere wurde das Verhalten des Sensors bei ungünstigen Wetterverhältnissen analysiert. Diese Untersuchungen dienten als Grundlage für die Modellierung des Radarsensors, mit dem Ziel, einerseits den zeitlichen Aufwand bei der Sensorverifikation zu verringern und andererseits kritische Anwendungsszenarien gezielt identifizieren zu können.
Da der Einsatz von Radarsensorik gegenüber anderen Sensorsystemen – insbesondere bei schlechter Witterung – bereits als vorteilhaft bekannt ist, bestand eine weitere Voraussetzung darin, die Ursachen für diese überlegene Leistungsfähigkeit detailliert zu erforschen und erklärbar zu machen. Die hohe Wiedergabetreue des Radarsensors wurde zudem genutzt, um die Genauigkeit weiterer Sensorsysteme durch Fusion zu optimieren.
Zur Überprüfung der im Projekt entwickelten Erweiterungen wurden zwei unterschiedliche Testumgebungen eingesetzt. Eine davon war die sogenannte Hardware-in-the-Loop-Umgebung, die es ermöglichte, den Radarsensor in einer realitätsnahen, aber kontrollierten Simulationsumgebung zu testen. Diese Methode stellte eine entscheidende technische Voraussetzung dar, um reproduzierbare und praxisnahe Testergebnisse zu erzielen.

1.2.2 Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

Entwicklung eines KI-basierten Modells zur Simulation von Witterungseffekten

Die KI-basierten Algorithmen zur Augmentation von Kameradaten bauten zunächst auf sogenannten Bild-zu-Bild-Verarbeitungsalgorithmen auf [3]. Diese Algorithmen ermöglichen es, ein Bild aus einer bestimmten Domäne inhaltsbasiert in eine andere Domäne zu transformieren. Im Rahmen des Projekts wurde dieser Ansatz beispielsweise genutzt, um eine bei klarem Wetter aufgenommene Verkehrsszene synthetisch mit Witterungseffekten wie Regen, Nebel oder Schnee zu versehen. Dadurch konnten aus bereits vorhandenen Datensätzen neue Varianten mit realistischen Schlechtwetterbedingungen generiert werden, ohne dass für jede Witterung separate reale Aufnahmen erforderlich waren.
Zum Projektbeginn galten Generative Adversarial Networks (GANs) [4] als der aktuelle Stand der Technik für diese Art der Bildtransformation. Diese Netzwerke bestehen aus zwei Komponenten: einem Generator, der versucht, möglichst realistische Bilder einer Ziel-Domäne zu erzeugen, und einem Diskriminator, der zwischen realen und synthetischen Bildern unterscheidet. Beide Modelle treten in einem sogenannten Min-Max-Spiel gegeneinander an, wodurch sie sich gegenseitig verbessern. Der Generator

lernt, immer überzeugendere Bilder zu erzeugen, während der Diskriminator darin trainiert wird, Fälschungen zuverlässig zu erkennen.
Ein wesentlicher Aspekt dieses Ansatzes ist jedoch die Verfügbarkeit repräsentativer Trainingsdatensätze aus den Ziel-Domänen. Nur durch ausreichende und qualitativ hochwertige reale Daten kann das Modell die stochastische Verteilung der Witterungseffekte korrekt erfassen und realistische Transformationen durchführen. Diese Herausforderung macht deutlich, wie wichtig es ist, bestehende Daten zu erweitern und alternative Ansätze zur Generierung synthetischer Wettereffekte zu entwickeln.
Im weiteren Verlauf des Projekts wurden daher Methoden zur domänenübergreifenden Adaption erforscht, um die Abhängigkeit von großen, annotierten Datensätzen zu reduzieren. Ziel ist es, robustere und generalisierbare KI-Modelle zu entwickeln, die eine zuverlässige Datenaugmentation ermöglichen und so die Leistungsfähigkeit von Wahrnehmungssystemen unter variablen Wetterbedingungen nachhaltig verbessern

Entwicklung einer Vorrichtung zur Erzeugung von Gischt

Der Stand der Forschung ist noch nicht vollständig erfasst, daher ist ein wesentlicher Aspekt des AI-SEE Projektes die Durchführung einer umfassenden Literaturrecherche zum Thema StraßenGischten. Zu diesem Zweck wurde ein separates Arbeitspaket eingerichtet. Die Ergebnisse dieses Arbeitspaket 1.1 werden einen Überblick über den wissenschaftlichen und technischen Fortschritt auf diesem Gebiet geben, der wiederum in die in Teilprojekt 2 des Projekts vorgestellten Entwicklungen einfließen wird.

Validierung und Verbesserung der Umfeldsensorik

Ein wesentliches Element der Umweltwahrnehmung unter schwierigen Witterungsbedingungen ist der Einsatz von Radarsensorik. Trotz ihrer bekannten Vorteile in solchen Szenarien ist es notwendig zu untersuchen, wie zuverlässig und genau Radarmessungen tatsächlich sind. Studien, wie jene von Hasirlioglu et al. [5], haben gezeigt, dass Regen eine dämpfende Wirkung auf Radarstrahlen hat, da die Reflexionswellen durch die Witterung abgeschwächt werden. Diese Abschwächung hat unmittelbare Auswirkungen auf die Berechnung des Radar Cross Section (RCS), was in weiterer Folge zu fehlerhaften Objektklassifizierungen führen kann.
Darüber hinaus haben Eder et al. [6] die Effekte der Mehrwegeausbreitung von Radarstrahlen analysiert. Ihre Untersuchung kam zu dem Ergebnis, dass es nicht eindeutig vorhersagbar ist, an welcher Stelle eines Objekts ein Radarstrahl auftrifft. Dieses Verhalten deutet auf eine zufällige Verteilung der Reflexionen hin und erschwert somit die präzise Lokalisierung und Interpretation von Messdaten in komplexen Szenarien.
Wald et al. [7] stellten zwei Methoden für Raytracing-Simulationen zur Erzeugung synthetischer Range-Doppler-Karten vor: SBR-PO und GO-PO. Beide nutzten ein 77 GHz-Radarmodell in einem Szenario mit zwei sich entgegenkommenden Fahrzeu-

gen, einer Brücke und einer Straßenschlucht. Trotz realistischer Ergebnisse bei hoher Szenenkomplexität erwies sich SBR-PO als rechnerisch sehr aufwendig. Dies verdeutlicht den Zielkonflikt zwischen Genauigkeit und Rechenaufwand bei der Anwendung solcher Verfahren in der Automobilentwicklung.
Schüssler et al. [8] entwickelten eine speziell für die Fahrzeugumgebung angepasste Raytracing-Methode, die ein materialbasiertes Modell mit diffuser Streuung einsetzt. Diese Erweiterung ermöglicht eine realistischere Simulation des Streuverhaltens von Radarwellen an unterschiedlichen Oberflächen – ein entscheidender Faktor für die Entwicklung und Erprobung von Radarsystemen im Automotive-Bereich.

1.3 Planung und Ablauf des Vorhabens

1.3.1 Teilprojekt 1: Entwicklung eines KI-basierten Modells zur Simulation von Witterungseffekten

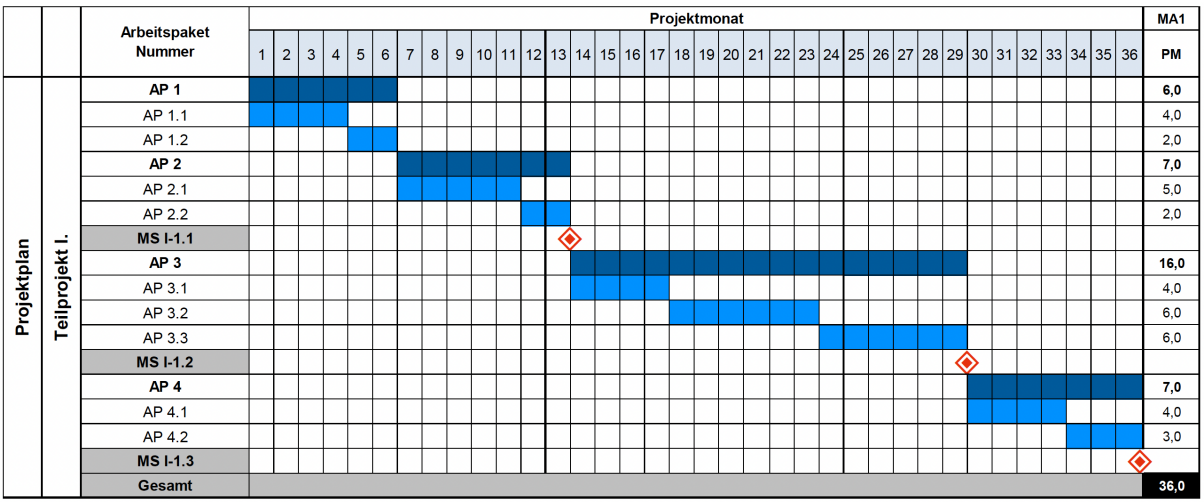


Abbildung 1: Gesamtübersicht Arbeitsplan - Teilprojekt 1

Ein zentraler Bestandteil dieses Projektabschnitts ist die Entwicklung KI-gestützter Modelle zur Simulation von Witterungseinflüssen auf Kamerabildern. Dafür wurden umfassende Literaturrecherchen durchgeführt, um den aktuellen Stand der Forschung zu analysieren und geeignete Methoden zu identifizieren. Zudem wurden spezielle Witterungsdatensätze erstellt und sorgfältig annotiert, um eine solide Grundlage für das Training und die Evaluierung der Modelle zu schaffen. Darüber hinaus wurden bestehende Ansätze weiterentwickelt und in realen Anwendungsfällen, insbesondere im Bereich der Objektdetektion, validiert. Ziel dieser Arbeiten ist es, die Robustheit von Wahrnehmungssystemen unter widrigen Wetterbedingungen signifikant zu verbessern und dadurch die Leistungsfähigkeit von KI-basierten Assistenz- und Automatisierungssystemen zu optimieren.

Vorarbeiten und Ermittlung von Kriterien fur realistische Witterungseinflusse

Im Rahmen von AP 1 wurden umfassende Literaturanalysen durchgeführt (AP 1.1) und verschiedene Ansätze zur KI-gestützten Simulation von Witterungseffekten untersucht. Der Schwerpunkt der Recherche lag auf Generative Adversarial Networks (GANs) [4], die in den letzten Jahren bemerkenswerte Fortschritte im Bereich der Bildgenerierung erzielt haben. Die Ergebnisse dieser Untersuchungen wurden auf der Ïnternational Conference on Intelligent Transportation Systems (ITSC2021)"veröffentlicht [9].
In Arbeitspaket 1.2 wurden die Auswirkungen von Witterungseinflüssen auf Kameradaten detailliert analysiert, um die Anforderungen an die in den folgenden Arbeitspaketen zu entwickelnden Algorithmen zu definieren. Dabei stellte sich heraus, dass eine flexible Parametrisierung der Algorithmen – beispielsweise durch Anpassung der Regenintensität oder der Nebelsichtweite – für eine praxisnahe Anwendung von entscheidender Bedeutung ist. Erste Ansätze zur Parametrisierung der Netzwerke wurden daher im Rahmen dieser Untersuchungen erforscht.

Erstellung eines Witterungsdatensatzes

Für das Training von Bildgenerierungsalgorithmen sind sowohl Klarwetter- als auch Schlechtwetterdatensätze erforderlich. Zu diesem Zweck wurde ein Datensatz aus öffentlich verfügbaren Bildern zusammengestellt, der verschiedene Witterungsbedingungen wie klares Wetter, Regen, Nebel und Schnee abdeckt. Ergänzend dazu wurde ein zweiter, kleinerer Datensatz (Datensatz 2) unter kontrollierten Bedingungen am CARISSMA in Ingolstadt aufgenommen, der die Domänen Klar, Regen und Nebel umfasst [9].
Darüber hinaus wurde am CARISSMA Outdoor-Gelände ein Spray-Datensatz erstellt, der verschiedene Versuchsfahrzeuge und eine Vielzahl an Sensoren – darunter Kamera-, Radar- und LiDAR-Systeme – umfasst [10]. Dieser Datensatz liefert wertvolle Informationen zur Wahrnehmung und Erkennung in herausfordernden Szenarien mit stark eingeschränkter Sicht.
Zusätzlich wurden zahlreiche externe Datensätze aus der Literatur untersucht [11, 12, 13, 14], um eine breite Grundlage für die Analyse und Evaluierung der entwickelten Methoden zu schaffen. Die gesammelten und annotierten Datensätze wurden sowohl für das Training der Algorithmen als auch als Benchmarking-Datensätze eingesetzt, um die Witterungsrobustheit der Modelle über eine Vielzahl an verschiedenen Bedingungen hinweg zu gewährleisten.

Entwicklung des KI-basierten Transformationsalgorithmus

Anwendungsdomäne erhebliche Einschränkungen bei der Bildtransformation mit sich bringt. Besonders betrachtet wurde das CUT-Framework [15], das stattdessen einen

Contrastive-Lossnutzt, um strukturelle Ähnlichkeiten zu bewahren, ohne die Flexibilität der Transformation übermäßig einzuschränken. Erste experimentelle Ergebnisse zeigen, dass die von CUT erzeugten Bilder eine vergleichbare Qualität zu den durch CycleGAN generierten Bildern aufweisen. Darüber hinaus wurden auch Style-Transfer-Ansätze [16, 17] analysiert, die sich jedoch als weniger erfolgversprechend erwiesen.
Im weiteren Verlauf des Projekts rückten Diffusionsmodelle [18] als vielversprechende Alternative zu GANs in den Fokus. Diese Modelle wurden gezielt untersucht, da sie in bestimmten Anwendungsfällen, insbesondere bei Schnee, deutlich bessere Ergebnisse lieferten. Während GANs häufig Schwierigkeiten bei der inhaltsbasierten Transformation aufwiesen, erzielten Diffusionsmodelle realistischere und präzisere Wettereffekte.
Zudem wurden Methoden entwickelt, um die Intensität der Witterungseffekte auf den Bildern gezielt zu steuern, da in Arbeitspaket 1.2 eine flexible Parametrisierung als entscheidende Voraussetzung für ein erfolgreiches Training von Detektionsalgorithmen identifiziert wurde. Zu diesem Zweck kamen ein Swapping Autoencoder (SAE) [19] sowie ein Diffusionsmodell auf Basis von ControlNet [20] zum Einsatz. Diese Ansätze ermöglichen eine präzisere Kontrolle der Witterungseffekte und tragen zur Verbesserung der Robustheit von Detektionsmodellen bei.

Validierung der simulierten Schlechtwetter-Daten

Im Rahmen von Arbeitspaket 4.1 konnte mithilfe synthetischer Daten nachgewiesen werden [21, 22], dass die Robustheit aller getesteten Detektionsmodelle unter extremen Wetterbedingungen signifikant verbessert wurde. Die untersuchten Modelle umfassten Faster R-CNN [23], FCOS [24], RetinaNet [**?**] und SSD [**?**].
Das Training der Detektionsmodelle führt zu einer erheblichen Steigerung ihrer Robustheit bei Nebel führte. Zudem konnte festgestellt werden, dass die erweiterten Trainingsdatensätze generell zu einer höheren Detektionsgenauigkeit bei starken Witterungsbedingungen beitragen. Dies belegt, dass der Ansatz der Datenaugmentierung auf eine Vielzahl von Detektionsmodellen generalisiert werden kann und sich somit leicht in weitere Forschungsarbeiten sowie industriell genutzte Algorithmen integrieren lässt.
Darüber hinaus bestätigten unsere Experimente, in Übereinstimmung mit vorherigen Studien, dass ein optimaler Split von synthetischen und realen Daten bei einem Verhältnis von 80% synthetischen zu 20% realen Daten liegt. Mit dieser Verteilung erzielten wir die höchste Detektionsgenauigkeit, was die Effektivität synthetischer Daten für das Training robuster Modelle weiter untermauert [21].

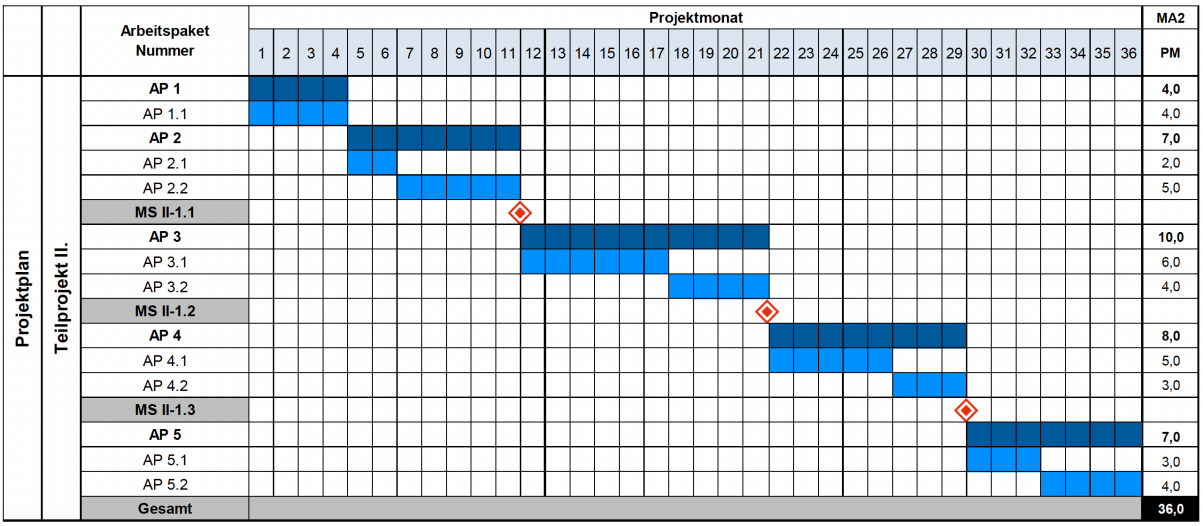


Abbildung 2: Gesamtübersicht Arbeitsplan - Teilprojekt 2

1.3.2 Teilprojekt 2: Entwicklung einer Vorrichtung zur Erzeugung von Gischt

Zentrales Element dieses Teilprojekts ist die Entwicklung einer Vorrichtung zur Erzeugung eines synthetischen Gischt, der reale Gischtdaten reproduzieren kann. Dies ermöglicht weiterführende Tests für automatisierte Fahrversuche, ohne dass ein reales Das Ziel dieses Teilprojekts ist die Entwicklung einer Vorrichtung zur Erzeugung von Gischt, die realistische und reproduzierbare Tests unter Laborbedingungen ermöglicht. Der Entwicklungsprozess beginnt mit einer umfassenden Literaturrecherche, um bestehende Lösungen zur Gischterzeugung zu analysieren und projektrelevante Erkenntnisse zu gewinnen. Parallel dazu wird ein Datensatz mit realen Messwerten erstellt, der als Grundlage für die Modellierung des Gischtgenerators dient. Mit Hilfe dieser Daten wird ein Modell des Generators entwickelt, das die Wechselwirkung zwischen Wasser und Luft realitätsnah abbildet. Zur Validierung der relevanten Parameter wird eine numerische Strömungssimulation durchgeführt.

Nach der Modellierungs- und Simulationsphase wird ein Prototyp gebaut, der in Testszenarien überprüft wird. Ziel ist es, einen Gischtgenerator zu entwickeln, der unter kontrollierten Bedingungen realistische Gischtmengen erzeugt, um die Auswirkungen auf die Sensoren und die Sichtverhältnisse zu simulieren. Der Generator wird so kalibriert, dass die Ergebnisse in Bezug auf Geschwindigkeit und Verschmutzungsgrad des Sensors unter realitätsnahen Bedingungen valide und reproduzierbar sind. Diese Einrichtung ermöglicht es der Automobilindustrie, automatisierte Fahrfunktionen effizient zu testen und die Auswirkungen von Gischt auf Sensoren unter verschiedenen Fahrbedingungen zu untersuchen.

Vorarbeiten und Sammeln von Basis-Wissen zum Thema Gischt

In der ersten Projektphase wurde eine umfassende Recherche zum Thema Gischt durchgeführt, Arbeitspaket 1.1: State-of-the-Art Recherche zum Thema Gischt. Dies beinhaltete die Analyse bestehender wissenschaftlicher Arbeiten, technischer Berichte und relevanter Studien zur Charakterisierung von Gischt und deren Einfluss auf Sensoren. Ziel war es, eine solide Wissensbasis für die Entwicklung des Gischtgenerators zu schaffen.

Planung des Gischt-Erzeugers

Im Rahmen dieser Phase wurden die Arbeitspakete 2.1: Erstellung eines Anforderungskatalogs und 2.2: Technische Planung des Sprayerzeugers abgeschlossen. Das Planungskonzept basierte auf einer Kombination aus Literaturrecherche und praktischen Versuchen zur Charakterisierung des Sprays. Dabei wurden reale Versuche durchgeführt, um Daten über das Zerstäubungsverhalten zu sammeln. Basierend auf diesen Erkenntnissen wurde geplant, wie die Gischtdüsen unter Berücksichtigung der wissenschaftlichen Grundlagen konstruiert werden sollten. Ein weiterer wichtiger Bestandteil der Planung war die Entwicklung einer geeigneten Metallkonstruktion zur Befestigung der Düsen (Nozzles). Dazu wurden Druckstudien durchgeführt, um die optimalen Betriebsparameter zu ermitteln. Zusätzlich wurde eine Struktursimulation durchgeführt, um sicherzustellen, dass die Konstruktion den Belastungen standhält.

Aufbau und Entwicklung des Gischt-Erzeugers

Ziel dieses Arbeitspaketes war die Konstruktion einer Vorrichtung zur Erzeugung kontrollierter Gischtbedingungen für Prüfstandversuche, unabhängig von Wetterbedingungen oder virtuellen Modellen. Als Ergebnis wurde ein Modell entwickelt, das aus einer Metallkonstruktion mit einer definierten Düsenanordnung besteht. Durch verschiedene Düsenaufsätze können unterschiedliche Tropfengrößen erzeugt werden. Zusätzlich wurde ein hydraulisches System zur Druckregelung integriert, um die Bedingungen für die Gischterzeugung genau steuern zu können. Zur flexiblen und realitätsnahen Simulation der Gischt wurde die Anlage in zwei Module mit je sechs Düsen unterteilt. Jede Düsenreihe kann individuell über ein Ventil und ein Manometer gesteuert werden. Um eine optimale Reproduktion realer Gischtszenarien zu gewährleisten, wurden verschiedene Düsenkonfigurationen und Eingangsdrücke getestet und zwei Konfigurationen als die realistischsten identifiziert. Diese wurden als Gischtintensität Eins und Gischtintensität Zwei bezeichnet und für die weitere Entwicklung übernommen.

Test und Validierung des Gischt-Erzeugers

Im Rahmen dieser Phas wurden die Arbeitspakete 4.1: Parametrisierung und Validierung der erzeugten Gischt und 4.2: Dynamischer Sensortest unter Gischteinfluss

durchgeführt. Das Gischtphänomen wurde mit Ansys Fluent und PreonLab simuliert und mit realen Daten aus AP 2.1 verglichen. Die Strömungsanalyse wurde mit der Finite-Volumen-Methode (FVM) durchgeführt, während für die Partikelsimulation der SPH-Ansatz (IISPH) verwendet wurde. Die Simulationen berücksichtigten reale Fahrversuche mit einem BMW Z4 und verschiedenen Haftwerten. Obwohl die Validierung nur qualitativ erfolgen konnte, zeigte sich, dass SPH-basierte Methoden für die Gischtmodellierung vielversprechend sind, aber noch weiterer Optimierung bedürfen.

Statische Tests wurde mit dem Gischtgenerator auf dem CARISSMA-Outdoor-Testgelände durchgeführt. Mit einer RGB-Kamera und einem 360 °-LiDAR wurden drei Szenarien getestet. Die Ergebnisse zeigen, dass die Gischtintensität einen direkten Einfluss auf die LiDAR-Punktwolken hat. Mit zunehmender Gischtintensität nimmt die Punktdichte ab und die Interferenzen durch die aufgewirbelten Tropfen werden deutlicher sichtbar. In Bereichen mit stärkerer Gischt wird die Punktwolke ungleichmäßiger und weist mehr Streuung auf, während bei geringerer Intensität die Punktwolke dichter und klarer bleibt. Zusätzlich wurde der YOLOv5-Algorithmus zur Objekterkennung in den Kameradaten eingesetzt. Die Analyse zeigte keine False Negatives, und die mAP-Bewertung ergab keine signifikante Beeinträchtigung der Erkennungsleistung. Dies wird darauf zurückgeführt, dass die Mindestdistanz von 10 m zwischen Ego-Fahrzeug und Spray eine Interferenz mit der Kamera verhinderte.

1.3.3 Teilprojekt 3: Validierung und Verbesserung der Umfeldsensorik

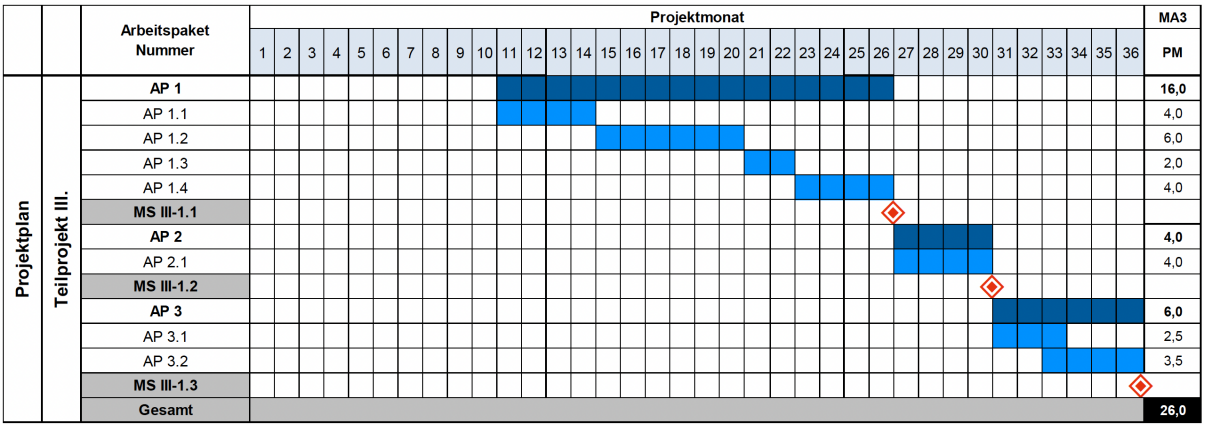


Abbildung 3: Gesamtübersicht Arbeitsplan - Teilprojekt 3

Im Rahmen dieser Teilprojket wird die Leistungsfähigkeit eines Automotive-Radarsensors zur zuverlässigen Umfelderfassung untersucht und optimiert. Dabei kommen gezielt Verbesserungs- und Fusionsalgorithmen zum Einsatz, um die Qualität der Sensordaten zu erhöhen. Ein besonderer Schwerpunkt liegt auf der Analyse des Sensorverhaltens unter widrigen Wetterbedingungen, da Radar in solchen Szenarien gegenüber anderen Sensoren bekannte Vorteile bietet. Um belastbare Aussagen über die Leistungsgrenzen und das Potenzial des Sensors treffen zu können, erfolgen umfangrei-

che Verifizierungen sowohl in realen Messungen als auch in simulationsgestützten Testumgebungen. Die Radarmodellierung spielt dabei eine zentrale Rolle: Sie soll helfen, den zeitlichen Aufwand bei der Sensorverifikation zu minimieren und gleichzeitig kritische Szenarien frühzeitig zu identifizieren. Langfristig zielt die Arbeit darauf ab, nicht nur die Ausgabequalität des Radarsensors selbst zu steigern, sondern auch andere Sensorsysteme durch die hohe Wiedergabetreue des Radars gezielt zu unterstützen.

Untersuchung und Modellierung des Radars

Im TP3.1 wurden verschiedene Testreihen durchgeführt. Die realen Messungen fanden in der CARISSMA-Halle unter Einsatz eines Forschungsradars, eines 4D-Serienradars sowie künstlich erzeugtem Regen statt. Parallel dazu kamen in der Simulation die Software ANSYS HFSS sowie der Konrad Vehicle Radar Target Stimulator zum Einsatz.
Niederschlag stellt eine wesentliche Ursache für Systemverluste dar. Dabei lassen sich drei Hauptverlustarten unterscheiden: Dämpfungsverlust, Materialverlust und Radomverlust. Für die durchgeführten Projektmessungen wurde ausschließlich der Signalverlust berücksichtigt, da als Ziel ein metallischer Eckreflektor eingesetzt wurde und das Radom im Rahmen der Untersuchungen nicht ausreichend analysiert werden konnte.
Die Messergebnisse zeigten, dass die Zielreflexion bei Regen an Signalstärke verliert. Zudem konnte beobachtet werden, dass sich im Nahfeld des Radars kleinere Reflexionen durch einzelne Regentropfen nachweisen ließen.

Verifizierung der Fusionsalgorithmen und Sensoren

In AP1.2 wurde ein Regenmodell auf Basis einer Dämpfungsgleichung implementiert und in den Vehicle Radar Target Stimulator integriert, um die Signalabschwächung in Abhängigkeit von Zielentfernung und Regenintensität zu simulieren. Zur realitätsnahen Darstellung weiterer Radareigenschaften kam IPG CarMaker® mit Raytracingbasiertem Material- und Reflexionsmodell zum Einsatz. Eine Notbremsfunktion demonstrierte die Auswirkung auf die Radardetektion, wobei eine erhöhte Unfallgefahr bei zunehmender Geschwindigkeit und Regenintensität festgestellt wurde.
Zudem wurde ein Ansatz zur Verbesserung der Radarklassifizierung entwickelt. Hierzu kamen zwei Convolutional Neural Networks (CNN) zum Einsatz, die Mikro-Doppler-Bilder von VRUs verarbeiteten.Die Lösung erreichte eine Klassifizierungsgenauigkeit von ca. 93% und berücksichtigte zusätzlich zwei weitere Verkehrsteilnehmertypen im Vergleich zu bestehenden Arbeiten.
Da die Tests unter idealen Bedingungen ohne Umgebungsstörungen durchgeführt wurden, traten keine Fehlklassifizierungen auf. Die Intensität der reflektierten Wellen nahm erwartungsgemäß mit der Entfernung ab, besonders bei nichtmetallischen Objekten. Die gewählte Aufteilung der Trainingsdaten nach Entfernungsbereichen erwies

sich daher als sinnvoll.

Aufbau und Verifizierung des Demonstrators

In TP3.1 das Messfahrzeug war mit einer Reihe von Umfelderfassungssensoren ausgestattet, darunter ein LiDAR, drei Radarsensoren, acht Kameras (davon sieben RGB-Kameras und eine Infrarotkamera), ein GPS sowie ein MARWIS-Sensor zur Erfassung des Straßenzustands. Für diese Arbeit wurden ausschließlich die LiDAR- und GPS-Daten analysiert.
Die praktischen Versuche fanden auf dem Außentestgelände des CARISSMA-IAD an der Technischen Hochschule Ingolstadt statt. Dieses Gelände bietet eine großzügige, asphaltierte und kontrollierte Umgebung mit minimalen Störeinflüssen für die Messungen. Für die Gischt-Simulation wurde eine 200 Meter lange Teststrecke gewählt, da sich in diesem Bereich eine Beregnungsanlage realisieren ließ und gleichzeitig hohe Fahrgeschwindigkeiten bei gleichbleibender Sicherheit für die Versuchsteilnehmer erreicht werden konnten.
Die Reflexion und Dämpfung von Radarstrahlen durch Wassertropfen in der Luft konnte experimentell nachgewiesen werden [25]. Die Analyse ergab, dass Regen den gemessenen RCS in Abhängigkeit von der Niederschlagsintensität und der Tropfengröße beeinflusst. Zudem wurde ein Rückgang des RCS mit zunehmender Entfernung zwischen Ziel und Sensor festgestellt. Abhängig von der Sendeleistung können Regentropfen selbst als Radarreflexion erscheinen; stärkere Reflexionen deuten auf eine größere Tropfenanzahl hin.

2. Eingehende Darstellung

2.1 Soll-Ist-Vergleich der geplanten und erzielten Ergebnisse sowie der eingesetzten Mittel

2.1.1 Teilprojekt 1: Entwicklung eines KI-basierten Modells zur Simulation von Witterungseffekten

Arbeitspaket 1.1: State-of-the-Art Research zum Stand der Technik fur Witterungssimulation (4 PM)

- **Beschreibung/Aufgaben:** In diesem Arbeitspaket wird der aktuelle Stand der Technik zu KI-basierten Algorithmen untersucht, die sich zur Simulation von Witterungseffekten auf Bilddaten eignen. Dazu wird eine umfassende Literaturrecherche durchgefuhrt und aktuelle Ergebnisse und Fortschritte auf diesem Gebiet betrachtet. Insbesondere werden dabei auch bisherige Arbeiten zum unuberwachtem Lernen mit GANs evaluiert. Diese benötigten fur das Training keine paarweisen Daten und eignen sich daher fur die Witterungssimulation. Der ge-

sammelte Entwicklungs- und Forschungsstand dient als Basis fur weitere Arbeiten im Projektverlauf.

- **Ergebnisse:** In diesem Arbeitspaket wurden aktuelle Methoden zur Bild-zu-Bild-Transformation analysiert, mit besonderem Fokus auf Architekturen für unüberwachtes Lernen. Ein häufiges Problem bei solchen Architekturen ist die Notwendigkeit einer semantischen Übereinstimmung zwischen den Bildern der Quell- und Zieldomäne, wie es beispielsweise bei Pix2Pix [26] der Fall ist. In der Realität treten jedoch selten identische Szenen unter verschiedenen Witterungsbedingungen auf, weshalb unüberwachtes Lernen hier besonders vorteilhaft ist. Dieser Ansatz nutzt zwei separate Verteilungen aus Quell- und Zieldomäne als Trainingsdatensatz, ohne dass exakte Bildpaare erforderlich sind.
  Zu den untersuchten Netzwerkarchitekturen gehörten CycleGAN [3], UNIT [3] und MUNIT [27]. Diese Modelle verwenden einen Cycle-Consistency-Loss", der die strukturelle Integrität zwischen Eingangs- und Ausgangsbild bewahrt. Ziel der Studie war der Vergleich der Bildqualität und der realistischen Darstellung von Wettereffekten durch verschiedene Netzwerke. Die Ergebnisse dieser Literaturrecherche wurden in Arbeitspaket 3.1 praktisch getestet und evaluiert.

Arbeitspaket 1.2: Analyse und Quantifizierung von Witterungseinflussen auf Bilddaten (2 PM)

- **Beschreibung/Aufgaben:** Zur Entwicklung robuster Algorithmen ist eine Analyse der Witterungseinflüsse auf Bilddaten erforderlich. Dabei werden wesentliche Kenngrößen für Regen, Nebel und Schnee ermittelt und deren Einfluss auf die Umweltwahrnehmung quantifiziert. Basierend auf diesen Erkenntnissen wird ein Anforderungskatalog erstellt und ein Bewertungsmaßstab für realistische Witterungssimulationen entwickelt.

- **Ergebnisse:** In diesem Arbeitspaket wurde der Einfluss von Witterung auf die Kamerasensorik und die Umwelt untersucht und Herausforderungen extrahiert. Umweltbedingungen lassen sich in vier Kategorien einteilen: Wetter (Wind, Regen, Schnee), wetterbedingte Straßenverhältnisse (stehendes Wasser, schneebedeckte Straßen), Partikel in der Luft (Nebel, Rauch) und Beleuchtung (Lichtverhältnisse, Tageszeit) [28]. Wetter und seine Effekte treten in vielen Formen auf und führen zu sichtbaren Veränderungen in der Szene. Eine realistische Wettersimulation erfordert mehr als das bloße Hinzufügen von Regentropfen oder Schneeflocken. Im Winter lagert sich Schnee auf Straßen und Gebäuden ab, während starker Regen nasse, reflektierende Oberflächen hinterlässt. Solche Bedingungen beeinträchtigen die Leistung von Kamerasensoren erheblich. Zudem verändern sich Vegetation und Himmelserscheinung je nach Jahreszeit und



Abbildung 4: Beispiele von Witterungseinflüssen auf Kameradaten.

Wetterlage. Die Einflüsse der einzelnen Witterungsfaktoren wurden in [10] publiziert und auf der Intelligent Vehicles 2021 in Alaska präsentiert.
Eine manuelle Simulation dieser komplexen Wetterveränderungen ist nicht praktikabel, doch für Objekterkennungs-Datensätze ist eine hohe Realitätsnähe erforderlich. Da Wetter in verschiedenen Intensitäten und Kombinationen auftritt (z. B. leichter oder starker Schneefall, Nebel über einer verschneiten Straße), sollte ein Adaptionsalgorithmus diese Variabilität erfassen, idealerweise durch gezielte Parametrisierung.

Arbeitspaket 2.1 und 2.2: Datensammlung und Vorverarbeitung der Daten (7 PM)

- **Beschreibung/Aufgaben:** Für das Training neuronaler Netzwerke wird ein vielfältiger Witterungsdatensatz benötigt. Dieser dient als Basis für die Algorithmen in Arbeitspaket 3 und soll verschiedene Witterungsbedingungen und Intensitäten (z. B. Regenstärke, Sichtweiten) abdecken. Dabei wird auf Erkenntnisse aus Arbeitspaket 1.2 zurückgegriffen. Der Datensatz soll Objekte wie Fahrzeuge, Fußgänger und Straßenschilder enthalten, die durch Witterung beeinflusst werden, sowie Umgebungseinflüsse wie nasse oder verschneite Straßen. Die Daten werden durch Realfahrten, Wettervorrichtungen, Simulationen und Online-Quellen gesammelt. Der Austausch mit Projektpartnern ist zentral, wobei die THI eine koordinative Rolle übernimmt. Für das Training der KI-Algorithmen müssen die in Arbeitspaket 2.1 gesammelten Daten annotiert werden. Dies umfasst die Vergabe von Tags, die Witterungszustände beschreiben, um eine effiziente Filterung und Nutzung des Datensatzes zu ermöglichen. Zudem werden Ansätze zur automatisierten Annotation untersucht und einheitliche Datenformate durch automatisierte Vorverarbeitungsprozesse sichergestellt.

- **Ergebnisse:** In Arbeitspaket 2.1 und 2.2 wurden verschiedene Datensätze mit unterschiedlichen Witterungseinflüssen gesammelt und für die weitere Nutzung aufbereitet. Die wichtigsten Datensätze sind:

Flickr-Datensatz: Dieser besteht aus kommerziell nutzbaren Bildern von Verkehrsszenarien mit jeweils 200 Bildern unter den Witterungsbedingungen klar, regnerisch, nebelig und verschneit. Die Bilder wurden über die Plattform Flickr gesammelt und zeigen sowohl deutlich sichtbare als auch extreme Witterungsverhältnisse. Alle Bilder wurden annotiert und können für Objektdetektionsalgorithmen sowie den Domänentransfer als Test- und Trainingsdatensatz genutzt werden.

Indoor-Datensatz: Dieser umfasst 295 klare, 210 neblige und 280 regnerische Bilder (siehe Abbildung 2 oben). Die Aufnahmen entstanden in der CARISSMA-Halle, die kontrollierte Regen- und Nebelsimulationen ermöglicht. Auf den Bildern ist ein Fahrzeug zu sehen, das sich mit 20 km/h von der Kamera entfernt. Die Nebel- und Regenbedingungen sind in diesem Datensatz besonders intensiv.

Spray-Datensatz: Aufgezeichnet auf dem Outdoor-Gelände des CARISSMA-Instituts (siehe Abbildung 2 unten), enthält dieser Datensatz Kamera-, Radar- und LiDAR-Daten von 13 verschiedenen Fahrzeugen in drei Szenarien. Die Fahrzeuge bewegen sich mit Geschwindigkeiten von 50 km/h, 60 km/h und 70 km/h über eine nasse Fahrbahn, um realistische Gischt zu erzeugen. Die Kameradaten wurden bereits annotiert, während die Radar- und LiDAR-Daten im dritten Projektjahr annotiert werden.

Zusätzlich wurden verschiedene öffentlich verfügbare Datensätze wie NuScenes [12], BDD100K [29], ACDC [14], DAWN [13] und Dense365 [30] analysiert. Unsere Untersuchung zeigte, dass viele große Datensätze nur wenige Schlechtwetterszenarien enthalten [11, 31], was ihre Eignung für das Training erheblich einschränkt. Diese Erkenntnis stärkt den Ansatz der Witterungsaugmentierung weiter. Alle genannten Datensätze werden in den folgenden Arbeitspaketen für das Training oder als Benchmarking-Datensätze verwendet.

Arbeitspaket 3.1: Evaluierung und Test vorhandener Algorithmen (4 PM)

- **Beschreibung/Aufgaben:** Dieses Arbeitspaket evaluiert die in Arbeitspaket 1.1 recherchierten Algorithmen anhand des gesammelten und annotierten Datensatzes. Es wird analysiert, wie gut sich die KI-Methoden zur Simulation von Witterungseffekten eignen und welche Herausforderungen bestehen. Vielversprechende Ansätze werden identifiziert und weiterentwickelt.

- **Ergebnisse:** In dieser wissenschaftlichen Arbeit wurden verschiedene Netzwerke getestet, die unüberwachtes Lernen ermöglichen, ohne auf paarweise Daten angewiesen zu sein. Abbildung 6 zeigt die Ergebnisse eines trainierten CycleGAN auf dem Flickr-Datensatz für Nebel, Regen und Schnee. Weitere Expe-

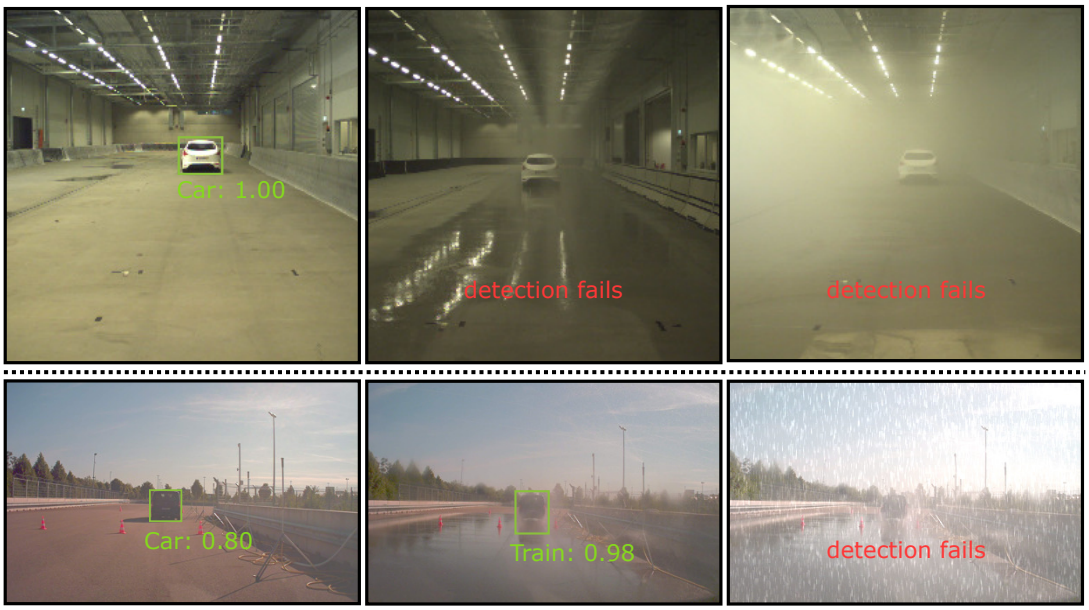


Abbildung 5: Indoor- und Spraydatensatz mit Detektionsresultaten.

rimente wurden mit UNIT, MUNIT und CUT durchgeführt, deren Ergebnisse in den entsprechenden Veröffentlichungen dokumentiert sind [9, 22].
Zur Bewertung der Bildqualität wurden Metriken wie die Fréchet Inception Distance"[32] und die Learned Perceptual Image Patch Similarity"[33] herangezogen. Die Analyse zeigte, dass CycleGAN auf den vorliegenden Datensätzen die höchste Bildqualität und die überzeugendsten Witterungseffekte erzielte.
Dieses Arbeitspaket identifizierte jedoch auch Grenzen bestehender Modelle. Während für Nebel bereits gute Ergebnisse erzielt wurden, erwiesen sich Schnee-Transformationen als problematisch. Die untersuchten Modelle fokussieren sich in ihrer Fehlerfunktion stark auf die Bildrekonstruktion, was zu einer hohen Bildqualität führt, jedoch größere inhaltsbezogene Veränderungen einschränkt. Dies verhindert beispielsweise die realistische Darstellung von Schneedecken auf Straßen. Bei Regen konnten nasse Fahrbahnen erzeugt werden, jedoch waren die simulierten Spiegelungen oft ungenau.

Arbeitspaket 3.2: (Weiter-) Entwicklung eines Transformationsalgorithmus (6 PM)

- **Beschreibung/Aufgaben:** Dieses Arbeitspaket greift die Erkenntnisse aus Arbeitspaket 3.1 auf und adressiert identifizierte Probleme. Ziel ist die Entwicklung eines Modells, das realistische Witterungseffekte simuliert, ohne die Semantik des Ausgangsbilds zu verändern. So soll eine Testfahrt unter klaren Bedingungen realistisch in regnerische Bedingungen transformiert werden, wobei Objekte nur stilistisch angepasst werden. Zur Verbesserung des Realismus werden neue Architekturen, Trainingsmethoden und Fehlerfunktionen eingesetzt. Zudem wird eine Parametrisierung zur kontrollierten Simulation von Witterungseffekten er-

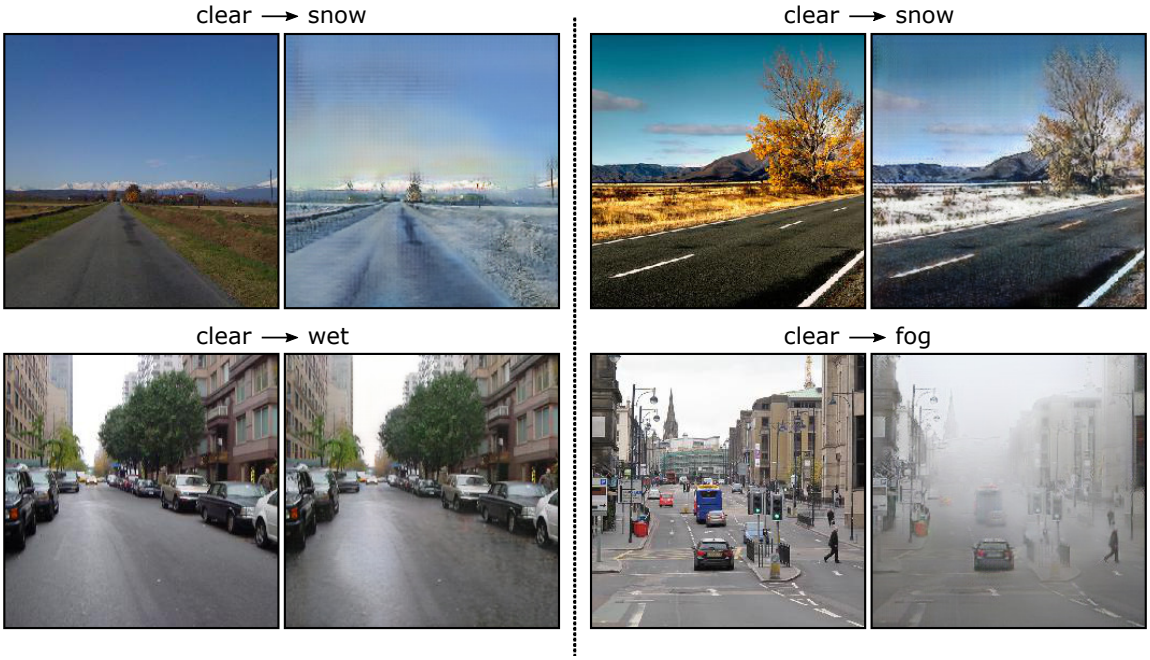


Abbildung 6: Ergebnisse der Witterungssimulation mit dem Netzwerk CycleGAN

forscht, um verschiedene Intensitäten wie leichten Nebel oder starken Schneefall zu simulieren. Der simulierte Wettereffekt soll multimodal sein, sodass verschiedene natürliche Ausprägungen nachgebildet werden können.

- **Ergebnisse:** Basierend auf diesen Ergebnissen wurde ein SAE-Netzwerk [19] analysiert. Ähnlich wie CUT verzichtet SAE auf Cycle-Consistencyünd nutzt stattdessen einen Patch Co-Occurrence Discriminator", der die Struktur und Textur eines Bildes effektiv voneinander trennt. Dadurch können Strukturvektoren mit verschiedenen Texturvektoren kombiniert werden.
  Zusätzlich erzeugt das SAE-Netzwerk einen Latent Space", der einfache arithmetische Operationen zur Anpassung der Texturintensität ermöglicht. Dies erlaubt eine gezielte Parametrisierung der Witterungseffekte (siehe Abbildung 3). Die präzise Rekonstruktion der Bilder stellt jedoch insbesondere bei detailreichen Szenen eine Herausforderung dar. Abbildung 7 zeigt die Traversierung des latenten Vektorraums mittels linearer Operationen zur Anpassung der Wetterintensität.

  Mit der rasanten Entwicklung von Diffusionsmodellen wurde deren Potenzial als Alternative zu GANs in Arbeitspaket 3.2 untersucht. Dabei wurde unter anderem das Modell Midjourney [**?**] analysiert. Diffusionsmodelle fügen während der Kodierung schrittweise Rauschen zu einem Bild hinzu und entfernen es im Dekodierungsprozess wieder, wobei die Rekonstruktion durch Text oder andere Bilder gesteuert wird. So kann beispielsweise ein Bild durch eine textuelle Beschreibung generiert werden, wie etwa *Ëin Foto mehrerer Autos bei starkem Schneefall auf einer verschneiten Straße"*.

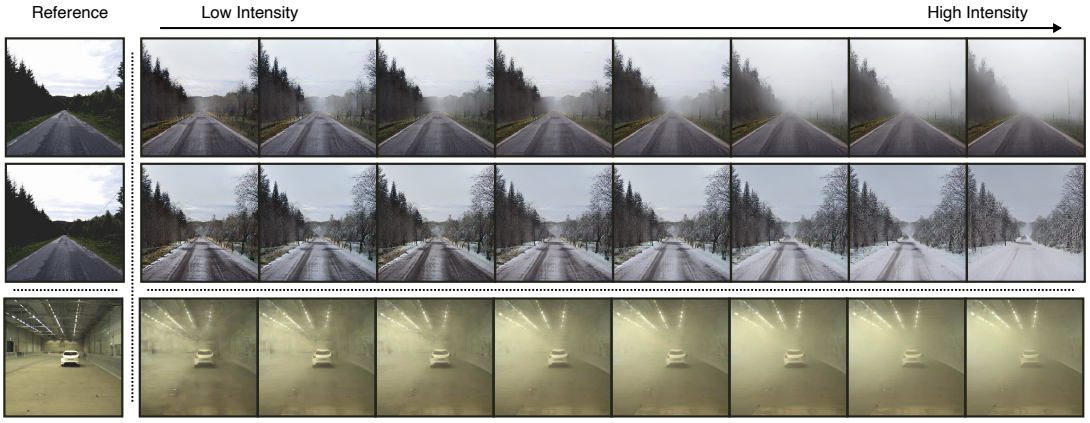


Abbildung 7: SAE Framwork mit parametrisierbarer Intensität.

Midjourney generiert Bilder ausschließlich aus Text, wodurch der zeitaufwendige Prozess der Datensammlung entfällt und eine Vielzahl von Szenarien unter Regen, Nebel und Schnee schnell erstellt werden kann. Alle Bilder wurden manuell annotiert, um eine hohe Qualität der Annotationen sicherzustellen. Die Ergebnisse dieser Untersuchung wurden auf der Winter Conference on Computer Vision (WACV) 2024 akzeptiert und präsentiert [21].
Zusätzlich wurden weitere Diffusionsmodelle wie CycleDiffusion [34], Plug and Play [35], ControlNet [20], MGIE [36] und SDXL [37] evaluiert. Diese Modelle eignen sich zur Augmentation von Realdaten. Die Untersuchungsergebnisse wurden auf der Intelligent Transportation Systems Conference (ITSC) 2024 vorgestellt. Abbildung 21 gibt einen Überblick über die Resultate der verschiedenen Diffusionsmodelle zur Datenaugmentation.



Abbildung 8: Überblick über die Resultate der Diffusionsmodelle.

Arbeitspaket 3.3: Optimierung des entwickelten Transformationsalgorithmus (6 PM)

- **Beschreibung/Aufgaben:** Witterungseinflüsse gehen über Regen und Schnee hinaus – nasse Fahrbahnen verursachen Spiegelungen, die Kamerasensoren verwirren, und Schnee kann Objekte teilweise verdecken. Dieses Arbeitspaket untersucht diese Umgebungseffekte detaillierter, um deren realistische Darstellung zu verbessern. Besonderes Augenmerk liegt auf der Optimierung sichtbarer Einflüsse wie Spiegelungen und Schnee. Dazu wird auch die Kombination mit anderen Lernmethoden, etwa Reinforcement Learning, geprüft. Zudem wird erforscht, wie die Intensität und Platzierung von Witterungseffekten im Bild gezielt gesteuert werden kann, beispielsweise durch gezieltes Markieren von Bereichen.

- **Ergebnisse: Arbeitspaket 3.3 ist eng mit Arbeitspaket 2.2 verknüpft, daher werden hier nur die wesentlichen Erkenntnisse zusammengefasst. In diesem Paket wurden die in Arbeitspaket 3.2 entwickelten Methoden weiter untersucht. Wichtige Effekte wie realistisch liegender Schnee oder Spiegelungen konnten durch den Einsatz von Diffusionsmodellen erzielt werden, sodass keine zusätzlichen Methoden entwickelt werden mussten. Besonders ControlNet [20] erwies sich als äußerst effektiv, um intensive Witterungseffekte in ein Bild zu integrieren, ohne die Semantik des Ausgangsbildes zu verändern.**
  Ein entscheidender Vorteil von Diffusionsmodellen gegenüber GANs besteht darin, dass sie nicht so stark an das Originalbild gebunden sind. Allerdings neigen sie dazu, die Szene stärker zu verändern als gewünscht. In späteren Arbeitspaketen wurde festgestellt, dass diese Eigenschaft problematisch für das Training von Detektionsalgorithmen sein kann.

Arbeitspaket 4.1: Bewertung und Validierung der simulierten Schlechtwetter-Daten (4 PM)

- **Beschreibung/Aufgaben:** Dieses Arbeitspaket validiert die in Arbeitspaket 3 entwickelten Algorithmen. Für Regen, Nebel und Schnee werden synthetische Schlechtwetter-Daten erzeugt und hinsichtlich ihres Realismus bewertet. Dabei kommen Bildmetriken, physikbasierte Simulationen der Partner (ANSYS, ILM) sowie die Regen- und Nebelanlage des CARISSMA zum Einsatz. Die Simulationen dienen zum Abgleich einzelner Transformationen. Zudem wird eine Studie mit Probanden durchgeführt, um die Realitätsnähe der generierten Wettereffekte zu bewerten.

- **Ergebnisse:** Im Verlauf des Projekts wurde festgestellt, dass eine subjektive Va-

lidierung keinen Nutzen für die Objektdetektion bietet, da Detektionsmodelle und Menschen Objekte unterschiedlich wahrnehmen. Ein Bild, das von Menschen als realistisch eingestuft wird, verbessert nicht zwangsläufig die Leistung eines Detektionsmodells. Daher lag der Fokus dieses Arbeitspakets auf der quantitativen Evaluierung augmentierter Daten mithilfe von Bildmetriken.
Tabelle **??** zeigt vier Metriken zur Bewertung der Bildähnlichkeit: Learned Perceptual Image Similarity Metric (LPIPS) [33], Structural Similarity Index Measure (SSIM) [38], Contrastive Learned Image Pretraining (CLIP) [39] und DINOv2 [40]. Diese Metriken vergleichen das reale Bild mit der augmentierten Version. Die Analyse ergab, dass LPIPS und SSIM stark mit der Intensität der Witterungseffekte korrelieren, während CLIP und DINOv2 die Semantik eines Bildes auf einer höheren Ebene bewerten.
Modelle wie CycleGAN oder MGIE erzeugen intensive Witterungseffekte, bewahren jedoch ausreichend semantische Ähnlichkeit zum Originalbild. Die Metriken wurden mit der Detektionsleistung korreliert, wobei sich zeigte, dass stärkere Witterungseffekte essenziell für ein robustes Training sind, während schwache Witterung nur einen geringen Einfluss hat. Die Ergebnisse dieser Evaluierung wurden auf der Intelligent Vehicles 2024 [22] präsentiert.

Arbeitspaket 4.2: Training mit synthetischen Schlechtwetter-Daten (3 PM)

- **Beschreibung/Aufgaben:** Dieses Arbeitspaket untersucht, ob synthetische Schlechtwetter Daten die Robustheit von Objekterkennungsalgorithmen verbessern. Dazu werden verschiedene Algorithmen mit diesen Daten trainiert und mit Modellen verglichen, die ohne Witterungseffekte trainiert wurden. Die anschließende Analyse quantifiziert den Nutzen synthetischer Daten für das Training und den Sensortest.

- **Ergebnisse:** Relevante Ergebnisse zum Training mit Schlechtwetterdaten wurden in [21] und [22] veröffentlicht. Es wurde gezeigt, dass synthetisch generierte Daten mit Midjourney effektiv genutzt werden können, um die Robustheit von Detektionsmodellen bei Nebel zu verbessern. Die synthetischen Daten wurden mit einer Klarwetter-Baseline sowie einem einfachen Nebelmodell verglichen und erzielten die besten Ergebnisse. Abbildung 9 (links) zeigt diese Ergebnisse für verschiedene Detektionsmodelle. Besonders bei schwierigen Nebelbedingungen konnte eine deutliche Steigerung der Robustheit festgestellt werden. Zudem führte die Kombination synthetischer Daten mit einem Anteil realer Klarwetterdaten zu einer weiteren Verbesserung der Robustheit. Der optimale Punkt wurde bei einem Verhältnis von 80 Für Diffusionsmodelle und die untersuchten GANs wurde eine Evaluierung auf dem erstellten Benchmark-Datensatz durchgeführt [22]. Dabei lieferten insbesondere CycleGAN und CUT überzeugende Ergebnis-

se und zeigten eine höhere Widerstandsfähigkeit gegenüber Störeinflüssen. Bei Diffusionsmodellen hingegen wurde festgestellt, dass viele Störeinflüsse die Detektionsleistung nicht in gleicher Weise beeinflussen wie bei GANs. Häufig wurden Objekte entfernt oder hinzugefügt, was zu unerwünschten Trainingseffekten führte. In [22] wurden daher Ansätze vorgestellt, um diesen Effekt zu minimieren und fehlerhafte Bounding Boxes zu entfernen, die während der Augmentation verloren gingen. Diese Optimierung hatte einen signifikanten Einfluss auf das Training und verbesserte die Ergebnisse sowohl für GANs als auch für Diffusionsmodelle.

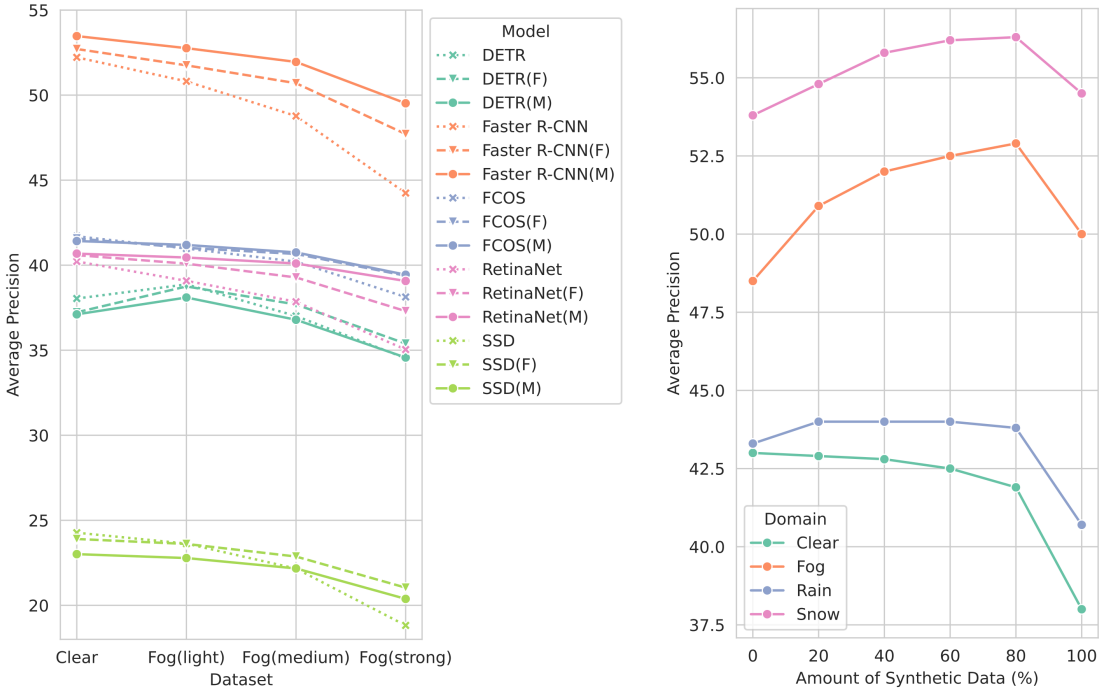


Abbildung 9: Resultate des Trainings mit synthetischen Daten. (Links:) Resultate bei Nebel (Rechts:) Resultate bei verschiedenen Anteilen an realen und synthetischen Daten.

2.1.2 Teilprojekt 2: Entwicklung einer Vorrichtung zur Erzeugung von Gischt

Arbeitspaket 1.1: State-of-the-Art Research zum Thema Gischt (4 PM)

- **Beschreibung/Aufgaben:** Ziel dieses Arbeitspakets ist es, den aktuellen Stand der Forschung zum Phänomen Gischt zu verstehen. Es umfasst eine umfassende Untersuchung der physikalischen Eigenschaften von Gischt und der wichtigsten Forschungsarbeiten zur Simulation von Gischt und deren Auswirkungen auf die Leistung automatisierter Fahrsysteme.

- **Ergebnisse:** Gischt entsteht durch das Abspritzen von Oberflächenwasser durch Fahrzeugreifen in die Luft und wird physikalisch als Kombination zweier unterschiedlicher Prozesse definiert: Splash und Spray [41, 42]. Obwohl diese Begriffe oft synonym verwendet werden, beziehen sie sich auf unterschiedliche Phänomene, die sich in den aerodynamischen Bedingungen, der Tröpfchengröße und den Entstehungsmechanismen unterscheiden. Jedes Tröpfchen hat seine eigene Größe und seinen eigenen Geschwindigkeitsvektor, der sowohl nach oben als auch nach unten gerichtet sein kann. Ihre Größenordnungen reichen von der Fahrzeuggeschwindigkeit bis zu niedrigeren Werten in der turbulenten Luftströmung hinter dem vorbeifahrenden Fahrzeug. Nach Weir et al. gibt es vier Mechanismen, die für die Wasserabgabe des Reifens verantwortlich sind: Bugwellen, Seitenwellen, Kapillarhaftung und Profilabsorption, wie in Abbildung 10 dargestellt.

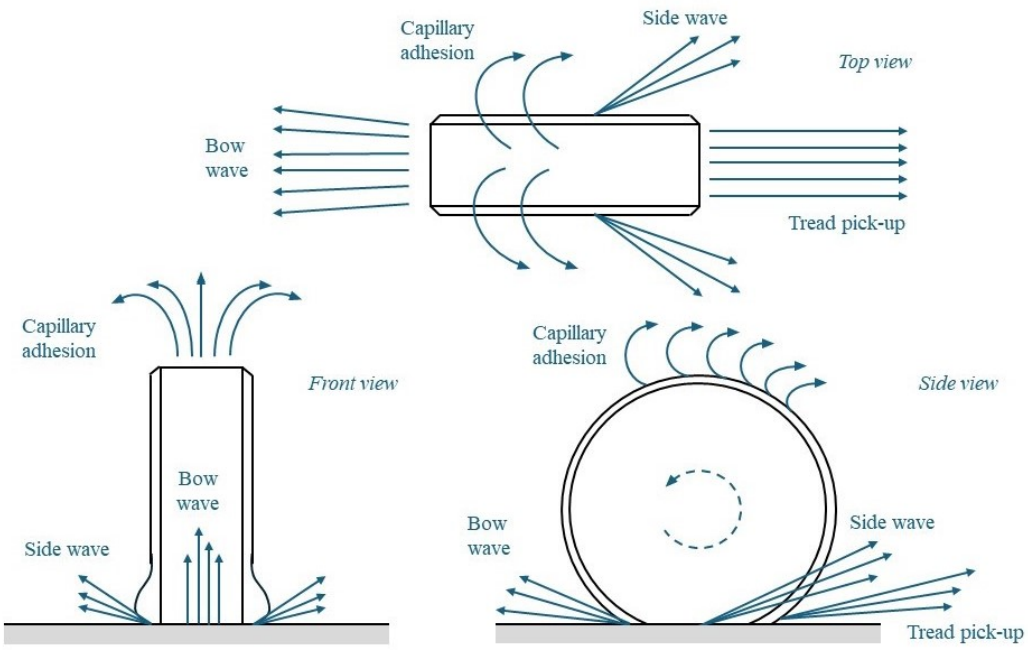


Abbildung 10: Gischt Mechanismen.

Die Bugwelle und die Seitenwelle erzeugen Wassertröpfchen, die von den Reifen weggeschleudert werden und das Splash verursachen. Dabei handelt es sich um größere Tröpfchen mit einem Durchmesser von mehr als 1,0 mm. Aufgrund ihrer größeren Masse unterliegen diese Tröpfchen einer stärkeren Trägheit und ihre Flugbahn kann als ballistische Flugbahn vom Reifen weg beschrieben werden.

Wasser, das durch die Profilrillen - Kanäle in der Lauffläche des Reifens - fließt, wird entweder sofort als Profilwasser in die Luft abgegeben oder durch Kapillarhaftung als dünner Film auf dem Reifen gehalten. Spray besteht aus kleinen Tröpfchen mit einem Durchmesser von typischerweise weniger als 0,5 mm. Auf-

grund ihrer geringeren Masse haben diese Tröpfchen eine geringere Trägheit. Dadurch bleiben sie länger im Nachlauf des Fahrzeugs suspendiert und können sogar eine Gischtfahne bilden.

Das Verständnis des aerodynamischen Verhaltens von Gischt ist für ein umfassendes Verständnis dieses Phänomens von entscheidender Bedeutung. Zur Modellierung des Gischtverhaltens wurden Techniken der numerischen Strömungsmechanik eingesetzt, die wertvolle Einblicke in die Tröpfchendynamik und deren Wechselwirkung mit der Fahrzeuggeometrie liefern [43, 44, 45, 46, 47, 48, 49].

Neben dem Stand der Technik zur Physik von Gischt wurde auch eine Literaturübersicht zur Interferenz dieses Phänomens mit Sensorsystemen durchgeführt. Gischt führt zu einem erheblichen Kontrastverlust in Kamerabildern und beeinträchtigt dadurch visuell basierte Detektions- und Trackingsysteme. Objekterkennungsalgorithmen sowohl für Lidar als auch für Kameras haben mit Fehlalarmen, ungenauen Objektgrößen und übersehenen Objekten zu kämpfen. [50, 51, 52, 53, 54].

Arbeitspaket 2.1: Erstellen eines Anforderungskatalogs (2 PM)

- **Beschreibung/Aufgaben:**In diesem Arbeitspaket geht es in erster Linie darum, gründliche Tests zu konzipieren und durchzuführen, die die realen Bedingungen simulieren und es uns ermöglichen, umfassende Gischtdaten zu sammeln. Durch die Durchführung dieser realitätsnahen Tests soll sichergestellt werden, dass die gewonnenen Daten genau analysiert und zur Rechtfertigung der am Gischtvorgang beteiligten Parameter verwendet werden können.

- **Ergebnisse:** Mit der Planung einer Versuchsreihe im realen Fahrversuch wurde im Arbeitspaket 2.1 begonnen. Als Versuchsgelände wurde das Outdoor-Testgelände der Technischen Hochschule Ingolstadt in der Nähe des Ingolstadt Villages genutzt. Als Ziel der Versuche wurde definiert Sensorrohdaten unter kontrollierten und quantifizierten Umweltbedingungen zu unterschiedlichen Zielfahrzeugen zu erfassen. Hierzu wurde zuerst das bestehende Versuchsfahrzeug um einen mobilen Straßenwetter-Sensor der Firma Lufft vom Typ Marwis ergänzt. Dieser ermöglicht die präzise Erfassung von unterschiedlichen Straßenzustandsparametern.

  Die Realexperimente fanden auf dem Outdoor Versuchsgelände des CARISSMA Instituts statt. Für die Gischtsimulation wurde eine Anlaufstrecke von 200m gewählt, da hier eine Beregnungsanlage installiert werden konnte. Die Fahrbahn wurde in 3,5 m breite Abschnitte unterteilt und mit 20 Sprinklern im Abstand von 1,5 m bewässert. Da es schwierig ist, Gischt bei niedrigen Geschwindigkeiten zu erzeugen, wurden Testfahrten bei höheren Geschwindigkeiten zwischen 80

km/h und 110 km/h durchgeführt. Die Szenarien umfassten 5 verschieden Positionierung und 10 Farzeuge. Die folgende Abbildung 11 zeigt vereinfacht die durchgeführten Tests.

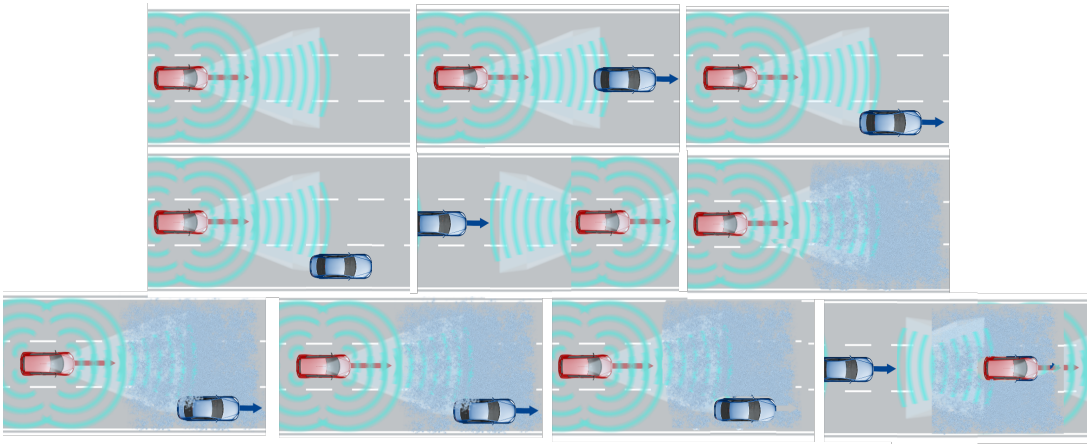


Abbildung 11: Die verschiedenen Messszenarien, die durchgeführt wurden, um Gischt Daten zu sammeln.

Das Messfahrzeug wurde mit verschiedenster Sensorik ausgestattet, darunter 1 Lidar, 3 Radar und 8 Kameras (7x RGB, 1x Infrarot) sowie einem MARWIS-Sensor zur Messung der Wassertiefe. Insgesamt wurden 4,5 TB Daten gesammelt. Das Videomaterial wurde aus verschiedenen Blickwinkeln aufgenommen, einschließlich dynamischer Aufnahmen des verfolgenden Messfahrzeugs (siehe Abbildung 12).

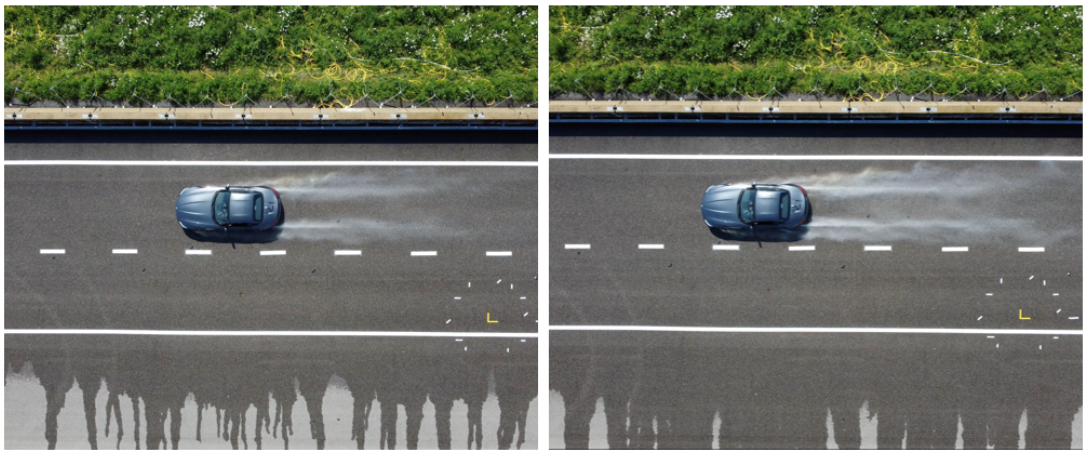


Abbildung 12: Birdview-Ansicht des Fahrversuchs. Links: 80km/h, Rechts: 110km/h.

Jedes Szenario wurde mit jedem der sieben Zielfahrzeuge mit drei unterschiedlichen Geschwindigkeiten wiederholt. Pro Geschwindigkeit wurde jeder Versuch dreimal durchgeführt, um eine höhere Datenbasis zu schaffen. Zusätzlich wurde jede Fahrt bei nassem und bei trockenem Untergrund durchgeführt, um einen Vergleichswert für die Sensorleistung unter normalen Bedingungen zu erfassen. Nach ausführlicher Planung und Vorbereitung wurden die Fahrversuche

vom 15.05.2023 bis zum 26.05.2023 durchgeführt. Es konnten dabei 711 Versuchsfahrten aufgezeichnet werden. Bei der Nachbearbeitung des Datensatzes viel auf, dass einige Aufnahmen bei Kopiervorgängen beschädigt wurden. Diese konnten jedoch durch händisches Post-Processing wiederhergestellt werden.

Die Untersuchung des Phänomens der Gischt offenbart ein komplexes physikalisches System, das von zahlreichen Faktoren beeinflusst wird. Die eindeutige Definition eines umfassenden Anforderungskatalogs hat sich als schwierig erwiesen, da eine Vielzahl von Parametern berücksichtigt werden muss. Interessanterweise haben die Tests einen klaren Trend gezeigt: Mit zunehmender Geschwindigkeit des Fahrzeugs nimmt auch die Intensität des Gischt zu. Diese Beobachtung deutet auf einen direkten Zusammenhang zwischen der Geschwindigkeit des Fahrzeugs und der Wirksamkeit der Sprayverteilung hin, so dass die Reproduktion von zwei Intensitäten des Sprays im Mittelpunkt steht. Eine ausführliche Durchsicht der vorhandenen Literatur zeigt, dass es einen entscheidenden Unterschied zwischen größeren und kleineren Tröpfchen gibt, der sich direkt auf ihr Verhalten und ihre Ausbreitung bei Gischtanwendungen auswirkt. Zu verstehen, wo sich größere Tröpfchen bilden und wo kleinere entstehen, ist ein grundlegender Parameter, dem wir in unserer Forschung Priorität einräumen.

Arbeitspaket 2.2: Technische Planung des Gischt-Erzeugers (5 PM)

- **Beschreibung/Aufgaben:** Auslegung der metallischen Struktur des Gischtbereichs unter Berücksichtigung von Struktursimulationen sowie Auswahl und Auslegung der Düsen zur Erzeugung der Gischttröpfchen.

- **Ergebnisse:** Das Konzept ist zunächst für statische Anwendungen. Der geplante Gischt-Simulator ist eine etwa 2 Meter lange und 50 Zentimeter hohe Vorrichtung, die mit Hilfe von Düsen verschiedene Wasserstrahlverteilungen darstellen kann. Der erste Schritt der Entwicklung war die Auswahl der Düsen, die für die Erzeugung der Gischtwolke verantwortlich sind. Jede Düse wurde aufgrund ihrer Eigenschaften und der zulässigen Drücke ausgewählt. Das Gischtphänomen wird in zwei Teile unterteilt: Splash bezieht sich auf größere Tropfen mit einem Durchmesser von mehr als 1,0 mm, die einer ballistischen Flugbahn folgen und vom Reifen wegfliegen. Im Gegensatz dazu besteht der zweite Teil Spray aus kleineren Tropfen, die normalerweise einen Durchmesser von weniger als 0,5 mm haben und in der Luft schweben. Es wurden vier Düsentypen ausgewählt, die in Abbildung 13dargestellt sind. Die Düsen auf der linken Seite erzeugen kleinere Tropfen und repräsentieren Spray, während die Düsen auf der rechten Seite Splash mit größeren Tropfen erzeugen.

  Zur Validierung des Strukturdesigns wurde eine Finite-Elemente-Analyse (FEA) mit der Software NX Nastran in Siemens Simcenter 3D CAE durchgeführt. Ziel



Abbildung 13: Düseneinstellung auf der linken Seite für Spray und auf der rechten Seite für Splash.

war es, die Spannungen in der Struktur aufgrund der durch die Wasserverdrängung erzeugten Kraft zu berechnen und die Steifigkeit des Entwurfs sowohl durch Modalanalyse als auch durch Strukturanalyse zu bewerten. Für die Strukturanalyse wurde die resultierende Wasserverdrängungskraft mit Hilfe des zweiten Newtonschen Gesetzes berechnet. Es war möglich, den Volumenstrom, die Dichte und die Austrittsgeschwindigkeit mit den Variablen des Gesetzes zu verknüpfen. Das Strukturnetz wurde vor der Simulation mit der berechneten Kraft erstellt. Um Rechenzeit und Hardwareanforderungen zu sparen, wurde ein 2D-Netz anstelle eines 3D-Tetraeder-Netzes erzeugt. Für den Generierungsprozess wurden die Materialeigenschaften des Aluminiumprofils (Aluminium 6061) den Netzparametern zugewiesen. Verschiedene Techniken und Anpassungen wurden verwendet, um eine qualitativ hochwertige Netzstruktur, wie in Abbildung 14 dargestellt, zu erhalten, insbesondere für die komplexen Verbindungen und Geometrien des Profils.

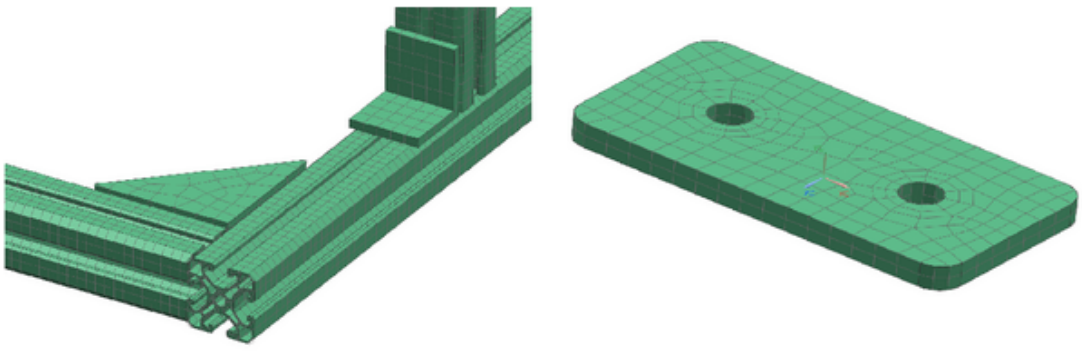


Abbildung 14: Maschen der Profile.

Mit dem über den Online-Durchflussrechner erhaltenen Volumenstrom wurde der berechnete Wasserdurchfluss an der Düse auf $3,13 \times 10^{-4} m^3$ festgelegt, was 1/16 des Eingangsdurchflusses entspricht. Mit dieser Information und einer Aus-

trittsgeschwindigkeit von 3,98 m/s wurde die Reaktionskraft von allen 16 Düsen berechnet, was zu einer Gesamtkraft von 20 N führte. Nach der Simulation wurden Verschiebungs- und Spannungsberichte erstellt, um die strukturelle Integrität und Verformung zu bewerten. Aufgrund der geringen Kraft betrug die maximale Verschiebung 0,2 mm. Die größte Verformung trat an der zentralen Verbindung des oberen Düsenträgers auf, wo die beiden Aluminiumprofile miteinander verbunden sind. Hinsichtlich der Spannungen wurde der Höchstwert von 1,357 MPa an den unteren 90-Grad-Verbindungen der Struktur beobachtet, wie in Abbildung 15 dargestellt. Unter Berücksichtigung der Streckgrenze des Werkstoffs der Profile (für Aluminium 6061 240 MPa), beträgt der Sicherheitsfaktor der entwickelten Struktur 177, so dass der maximale Spannungswert ebenfalls als unbedeutend angesehen werden kann.

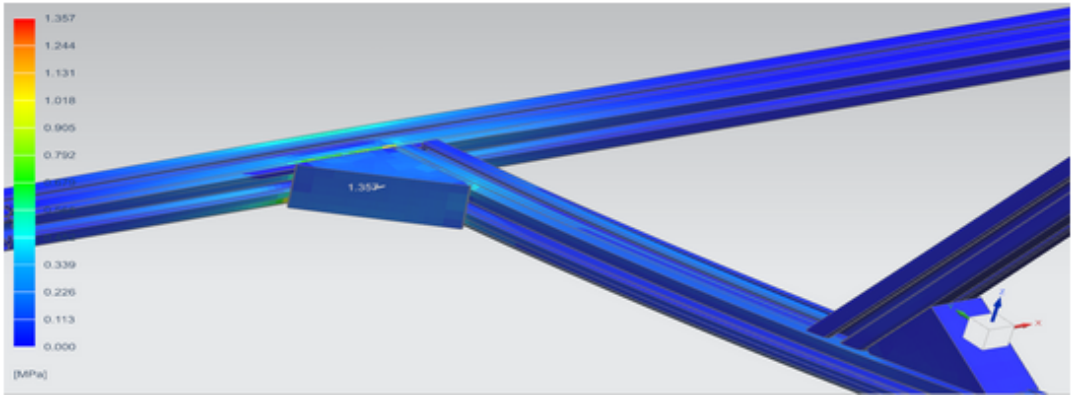


Abbildung 15: Spannungsverteilung in der Metallstruktur.

Nachdem die Metallstruktur erfolgreich simuliert wurde und die Ergebnisse vielversprechend sind, besteht der nächste Schritt darin, mit dem Arbeitspaket 3.1 fortzufahren, um die Struktur zu bauen und die Düsenkonfigurationen zu definieren.

Arbeitspaket 3.1: Aufbau und Beschaffung (6 PM)

- **Beschreibung/Aufgaben:** In diesem Arbeitspaket wird die Konstruktion eines Modells für eine Gischtvorrichtung vorgeschlagen, um kontrollierte Gischtbedingungen für Prüfstandtests unabhängig von Wetterbedingungen und virtuellen Modellen zu schaffen.
- **Ergebnisse:** Das Modell besteht aus einer Metallstruktur mit einer definierten Düsenanordnung, welche durch unterschiedliche Düsenaufsätze individuelle Tropfengrößen erzeugen kann, sowie einem hydraulischen System zur Druckregelung. Man einigte sich darauf, die Struktur in zwei Teile mit jeweils sechs Düsen zu unterteilen und den Wasserdruck jeder Düsenreihe individuell durch ein Ventil und ein Manometer zu steuern. Um ein reales Szenario der Sprayerzeugung

besser darstellen zu können, musste der Simulator mit verschiedenen Düsenkonfigurationen und Druckwerten für den Eingangswasserstrom getestet werden. Zu diesem Zweck wurde ein Prüfplan entwickelt, der die meisten möglichen Variationen abdeckt, wobei die verschiedenen Düsen für bestimmte Positionen entsprechend den Mechanismen der Gischterzeugung und der daraus resultierenden Tropfengröße priorisiert wurden. Die 19 Tests wurden jeweils eine Minute lang aufgezeichnet, siehe Abbildung 16.

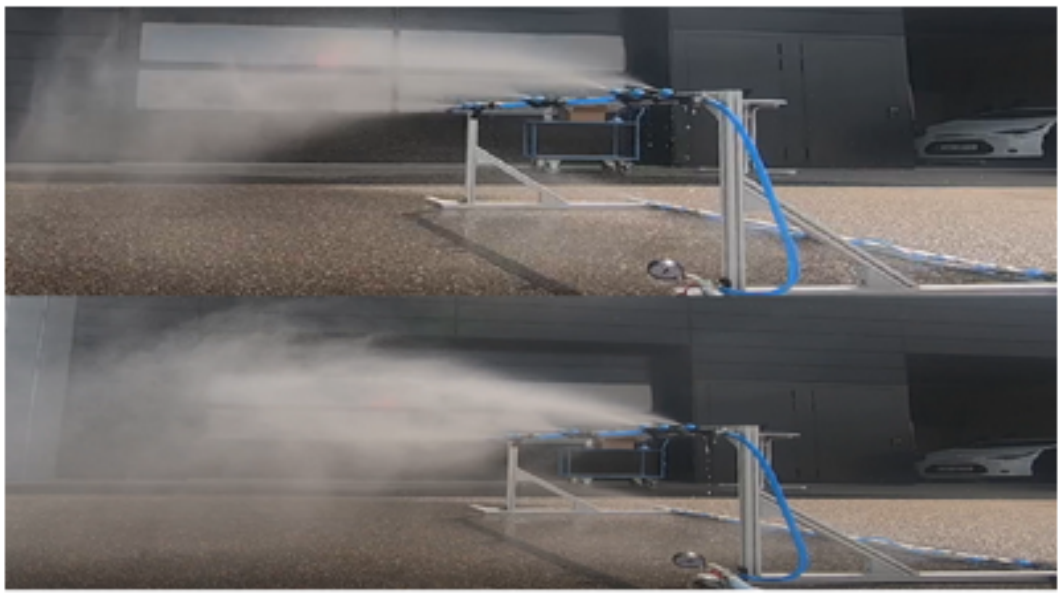


Abbildung 16: Zwei verschiedene Düsenkonfiguration im Vergleich.

Nach der Analyse der Bilder und dem Vergleich mit den realen Gischtdaten aus den Versuchen in Arbeitspaket 2.1 wurde beschlossen, mit zwei Konfigurationen fortzufahren, die in Bezug auf die Qualität die realistischsten Ergebnisse lieferten. Die beiden ausgewählten Konfigurationen wurden als Gischtintensität Eins und Gischtintensität Zwei bezeichnet.

Arbeitspaket 3.2: Entwicklung der Steuerungssoftware (4 PM)

- **Beschreibung/Aufgaben:** Das Hauptziel dieses Arbeitspaketes war die Entwicklung der Steuerungssoftware für den Gischtsimulator. Der Mikrocontroller sollte die Hauptfunktionen wie die Regelung der Wasserzufuhr und die Anpassung der Rotationsgeschwindigkeit steuern.
- **Ergebnisse:** Bisher lag der Schwerpunkt auf der Realisierung der Druckregelung, die manuell eingestellt wurde. Eine vollständige Automatisierung des Systems wurde noch nicht erreicht, da das Gischtsystem noch validiert werden muss, bevor eine vollständige Automatisierung erfolgen kann.

Arbeitspaket 4.1: Parametrisierung und Validierung der erzeugten Gischt (5 PM)

- **Beschreibung/Aufgaben:** In diesem Arbeitspaket wird eine Simulation des Gischtphänomens durchgeführt und ein Vergleich mit realen Gischtdaten aus AP 2.1 durchgeführt, um die Simulation zu validieren.

- **Ergebnisse:** Im Rahmen von AP 4.1 wurden die Simulation des Gischtphänomens schrittweise nachgebildet. Zunächst diente die Geometrie eines BMW Z4 als Ausgangspunkt für die Analyse und Simulation, da dieser für Validierungsfahrten verwendet wurde. Die Untersuchung des Strömungsfeldes um die Fahrzeuggeometrie wurde anschließend mit Ansys Fluent durchgeführt. Ein Schwerpunkt war die Modellierung des Strömungsfeldes mit der Finite-Volumen-Methode (FVM), die als Grundlage für die Partikelsimulation diente. Die Anwendung des Euler-Lagrange Ansatzes, wie in der Literatur üblich, erforderte eine genaue Modellierung des Einflusses der Luftströmung auf die Fluidpartikel. Die Berechnung wurde mit Fault Tolerant Meshing und 1000 Iterationsschritten durchgeführt, da bereits ein stationäres Verhalten festgestellt wurde. Das Ergebnis der Arbeit ist in Abbildung 17 dargestellt.

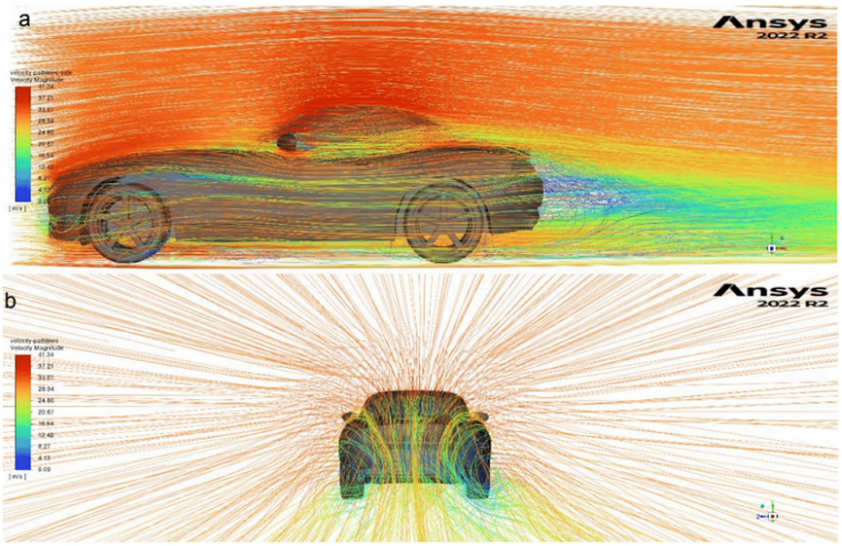


Abbildung 17: Seitenansicht (a) und Rückansicht (b) des Bahnlinienverlaufs der Geschwindigkeit.

Zur Modellierung des Gischtvorgangs wurde die Software PreonLab vom Projektpartner Fifity2 eingesetzt. Im Gegensatz zu herkömmlichen CFD-Verfahren verwendet PreonLab einen partikelbasierten Ansatz namens Implicit Incompressible SPH (IISPH), der eine Weiterentwicklung der klassischen SPH darstellt. Der Simulationsaufbau integrierte die Rahmenbedingungen der Fahrversuche genau: Das Fahrzeug wurde am Anfang der Straße positioniert, mit Geschwindigkeiten für Fahrwerk und Reifen, die den realen Fahrversuchen entsprachen.

Die Bewegungsabläufe wurden definiert, und die Flüssigkeitsemissionen wurden durch eine volumetrische Quelle erzeugt. Die dimensionslosen Parameter Roughnessünd Ädhesion"wurden auf der Grundlage von experimentellen Versuchsreihen definiert, um ihren Einfluss auf die Ergebnisse zu analysieren. Zur Validierung der Gischtsimulation mit der SPH-Methode erfolgt ein Vergleich der simulierten Ergebnisse mit dem realen Fahrversuch bei 110 km/h. Allerdings wurde der Vergleich nur qualitativ durchgeführt, da die Daten ohne den Einsatz von fluoreszierenden Farbstoffen oder spezieller Sensorik Sensortechnik aufgenommen wurden und daher nur eine qualitative Bewertung zulassen. Der Vergleich konzentriert sich auf die Simulationen mit den Haftwerten 50, 100 und 200, wobei der Adhäsionswert 0,65 aufgrund fehlender Circumferential Gischts von diesem Vergleich ausgeschlossen wird. Ein Beispiel für einen Vergleich ist in Abbildung 18 dargestellt.

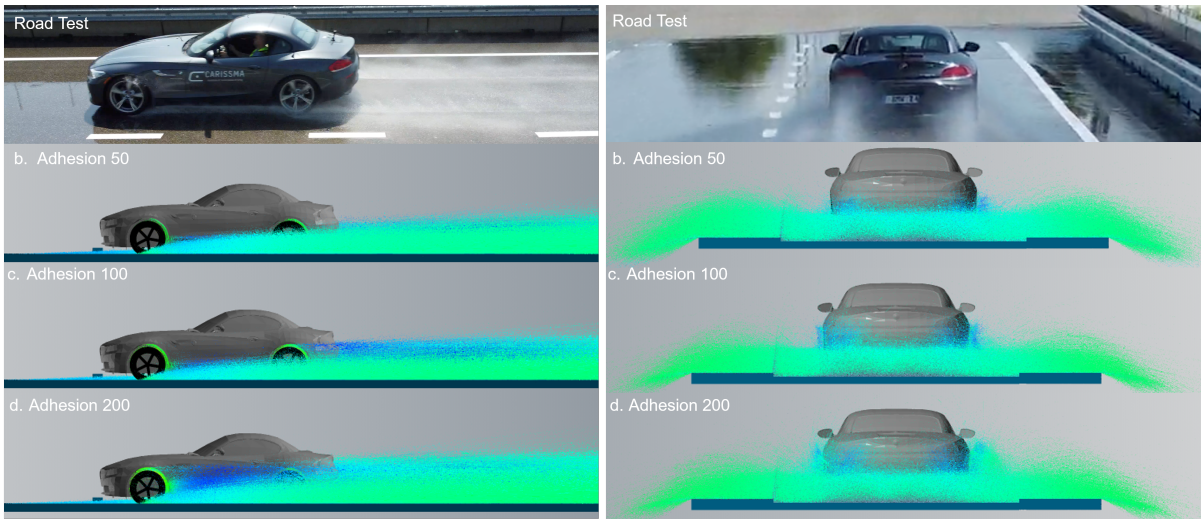


Abbildung 18: Vergleich der Gischtentwicklung aus der Rückansicht.

Die obigen Ausführungen zeigen, dass die Simulation von Gischt ein komplexes Problem darstellt, für das bisher keine vollständige Lösung existiert, die alle relevanten physikalischen Phänomene umfassend berücksichtigt. Verschiedene numerische Verfahren weisen jeweils Vor- und Nachteile auf, wobei insbesondere SPH als vielversprechende Alternative für Partikelsimulationen angesehen werden kann. Die Einfachheit des Simulationsaufbaus und die Fähigkeit, Mehrphasenströmungen zu modellieren, machen SPH attraktiv, obwohl methodische Einschränkungen bei der Validierung bestehen. Die Ergebnisse unterstreichen das Potenzial von SPH für eine realistische Simulation der Gischtbildung. Es wird jedoch betont, dass Simulationen allein nicht ausreichen und umfangreiche Fahrversuche erforderlich sind, um die Auswirkungen von Gischt genau zu bewerten und die Fahrzeugsicherheit zu verbessern. Diese Ergebnisse weisen auf die Notwendigkeit hin, ein Gischtsimulationsmodell zu entwickeln, um neue und

reproduzierbare realistische Tests durchzuführen und die Forschung auf diesem Gebiet voranzutreiben.

Arbeitspaket 4.2: Dynamischer Sensortest unter Gischt-Einfluss (3 PM)

- **Beschreibung/Aufgaben:** Aufgrund der Komplexität des Gischtphänomens wurden keine dynamischen Tests durchgeführt; stattdessen wurde der Gischtgenerator verwendet, um die Verschlechterung der Sensordaten zu erfassen.
- **Ergebnisse:** Der entwickelte Gischt-Simulator bietet eine innovative Möglichkeit, Sensoren gezielt auf ihre Empfindlichkeit gegenüber Gischt zu testen. Um Daten über Gischt zu sammeln und die Interferenz des Modells mit den Sensoren zu verstehen, wurden statische Tests zur Datenerzeugung im CARISSMA Outdoor durchgeführt. Drei Szenarien wurden entsprechend den Tests von AP2.1 mit den beiden Gischt-Intensitäten sowie als Referenz ohne Gischt reproduziert. Die Tests wurden bei drei verschiedenen Entfernungen durchgeführt. Die Daten wurden mit einer RGB-Kamera und einem 360° lidar im rosbag 2-Format erfasst. Die Abbildung 19 zein Beispiel der Ergebnisse des Testszenarios mit dem Fahrzeug an der Seite in 10 m Entfernung.

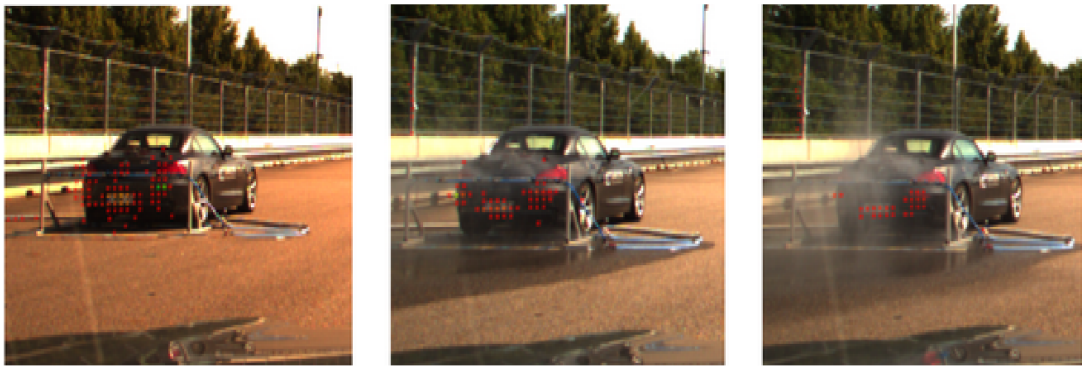


Abbildung 19: Drei Auswirkungen von drei verschiedenen Gischt Konfigurationen auf Lidar Punktwolken.

Es ist zu erkennen, dass die Verschlechterung der Punkte mit zunehmender Gischt zunimmt (siehe Abbildung rechts), wobei die Intensität der Lidarpunkte in den betroffenen Gebieten deutlich abnimmt. Dies deutet darauf hin, dass die Intensität der Gischt und die aufgewirbelten Tröpfchen die Genauigkeit und Klarheit der Lidardaten beeinträchtigen. Das Lidar, das ursprünglich klare und genaue Punktwolken lieferte, zeigt eine deutliche Verringerung der Punktdichte und der Intensität der aufgezeichneten Daten aufgrund der Dispersion und der Tröpfchenbildung in der Gischt. Zur Analyse der Objekterkennung auf den Kamerabildern wurde der YOLOv5-Algorithmus verwendet, Abbildung 20. Es wurde überprüft, inwieweit die Gischt die Erkennungsgenauigkeit beeinflusst.

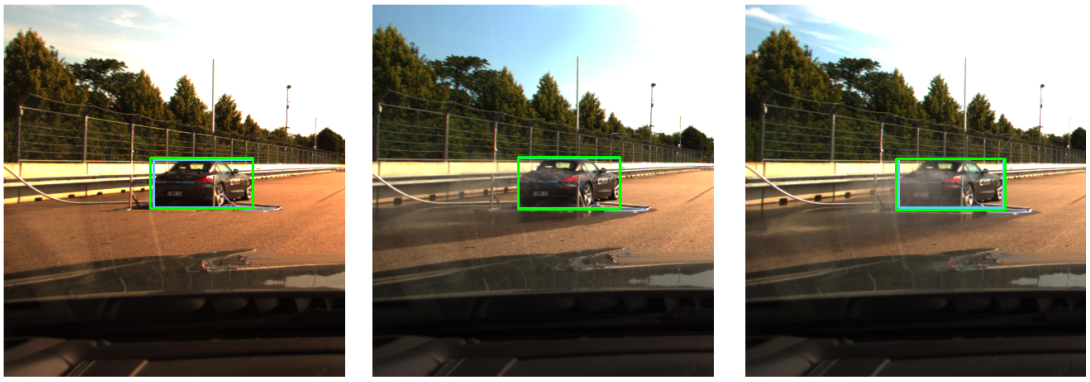


Abbildung 20: Drei verschiedenen Gischt Konfigurationen mit object detection

YOLO wurde angewendet und die Reduktion betrug nur 1% für Intersection over Union (IoU). Dies bedeutet, dass die Unterschiede zwischen den Szenarien gering sind. Es wurden keine False Negatives gefunden und die Differenz zwischen Ground Truth und erkannten Objekten wurde anhand der Mean Average Precision (mAP) bewertet. Die Ergebnisse zeigen, dass die Erkennungsleistung nicht signifikant beeinträchtigt wurde. Ein möglicher Grund dafür ist die relativ große Entfernung zwischen dem Ego-Fahrzeug und dem Spray (mindestens 10 m im kleinsten Szenario), wodurch das Wasser keine signifikante Interferenz mit der Kamerawahrnehmung verursachte. Diese Beobachtungen bestätigen, dass Gischt die Sensorwahrnehmung unterschiedlich beeinflusst, wobei LiDAR-Daten deutlich störanfälliger sind als Kameradaten.

2.1.3 Teilprojekt 3: Validierung und Verbesserung der Umfeldsensorik

Arbeitspaket 3.1: Untersuchung von Radar-Störeffekten unter verschiedenen Witterungsbedingungen (4 PM)

- **Beschreibung/Aufgaben:** Zur Untersuchung des Einflusses unterschiedlicher Witterungsbedingungen auf den Radar, werden zunächst wetterabhängige Szenarien in einer simulationsfähigen Umgebung erzeugt, anschließend in Realversuchen nachgestellt und mithilfe eines entwickelten Realitätsmaßes hinsichtlich ihrer Übereinstimmung mit den simulierten Signalen bewertet.

- **Ergebnisse:** Die durchgeführten Realmessungen wurden mit dem Stand der Technik verglichen. Dabei wurde festgestellt, dass Regen das Radarsignal dämpft – abhängig von der Entfernung zum Zielobjekt sowie der Regenintensität. Dieser Zusammenhang kann durch die folgende Gleichung beschrieben werden:

$$P_e = \frac{P_S G^2 \lambda^2}{(4\pi)^3 R^4} \cdot \frac{\pi \theta \varphi R^2 c_0 \tau}{8} \cdot \frac{\pi^5}{\lambda^4} \cdot |k_w|^2 \cdot \int_0^\infty N(D,r) D^6 \, dD \tag{1}$$

mit den folgenden Parametern:

(i) P_e = Empfangsleistung (ii) P_S = Sendeleistung (iii) G = Antennengewinn (iv) λ = Wellenlänge (v) R = Entfernung zum Ziel (vi) θ = horizontaler Abstrahlwinkel (vii) φ = vertikaler Abstrahlwinkel (viii) c_0 = Lichtgeschwindigkeit (ix) τ = Empfangspulsdauer (x) k_w = komplexer Brechungsindex von Wasser (xi) $N(D, r)$ = Tropfengrößenverteilung in Abhängigkeit von Tropfendurchmesser D und Entfernung r

Die Gleichung beschreibt, wie stark das Radarsignal durch die Interaktion mit Regentropfen abgeschwächt wird. Dabei spielen sowohl die physikalischen Eigenschaften des Wassers als auch die Verteilung und Größe der Tropfen eine zentrale Rolle.

Das vorgeschlagene Regen-Dämpfungsmodell für Radarsignale zeigt vielversprechende Simulationsergebnisse im Vergleich zu den realen Messdaten, wie auch in [55] dargestellt. Der simulierte Leistungsverlust liegt innerhalb der von den Sensoren gemessenen Minimal- und Maximalwerte. Dennoch wird die Simulation stark durch die Tropfengrößenverteilung sowie die berechnete Extinktionsquerschnittsfläche beeinflusst. Daher sind präzise Regenmessungen und eine genaue Erfassung der Streueffekte einzelner Tropfen für realitätsnahe Simulationsergebnisse zu empfehlen.

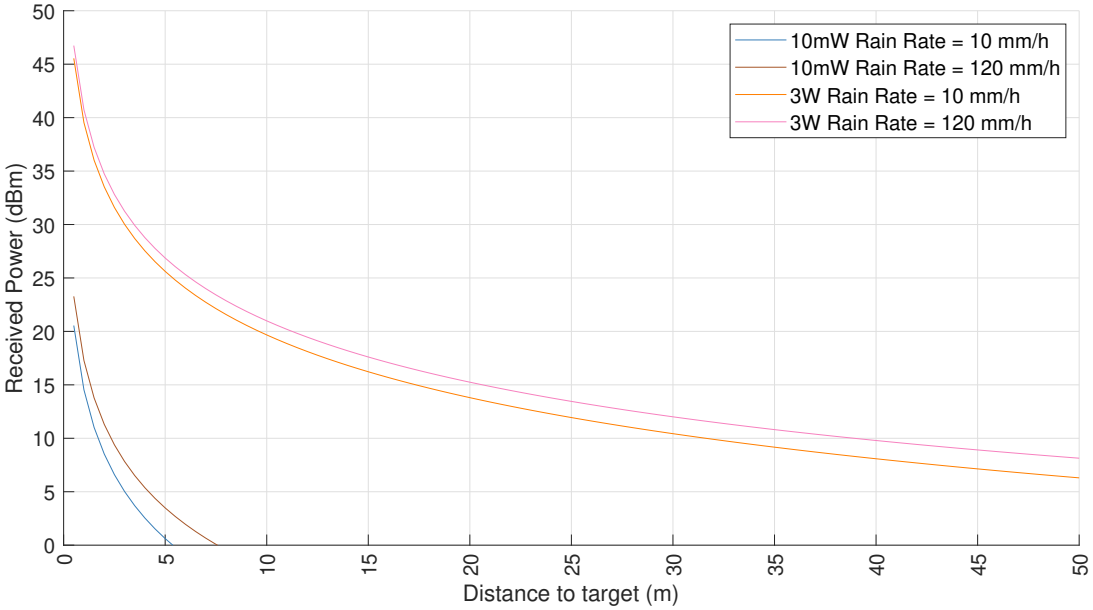


Abbildung 21: Überblick über die Resultate der Diffusionsmodelle.

Die Analyse zeigte, dass die Regenintensität das gemessene RCS proportional zur Tropfenanzahl je Tropfengröße in der Luft beeinflusst. Es wurde ein Rückgang des gemessenen RCS mit zunehmender Entfernung zwischen Sensor und Ziel festgestellt, was auch in der Studie von Gourova et al. [56] beobachtet wurde. Zu-

dem konnte nachgewiesen werden, dass nasser Asphalt die Mehrwegeausbreitung verstärkt, wodurch die Fähigkeit des Sensors zur korrekten RCS-Erfassung weiter eingeschränkt wird. Darüber hinaus wurde festgestellt, dass sowohl die Entfernung als auch die Regenintensität die Standardabweichung der Messwerte erhöhen.

Arbeitspaket 3.2: Verbesserung der Radarsignale vor der Fusion (6 PM)

- **Beschreibung/Aufgaben:** In diesem Arbeitspaket wird ein Modell zur Verbesserung der Radardaten entwickelt. Witterungseinflüsse und Clutter können die Sensorausgabe verfälschen und Geisterobjekte oder ungenaue Objektparameter verursachen. Ziel ist es, ein kognitives Modell zu nutzen, das die Umgebung versteht, Störeinflüsse herausfiltert und die Objekterkennung verbessert. Das finale Modell wird mit den Ergebnissen aus Arbeitspaket 3.1 verglichen und validiert.

- **Ergebnisse:** In Rahmen von Arbeitspaket 1.2, wurde die Wirksamkeit der Raytracing-Technologie und des HFSS SBR+-Tools von ANSYS für realistische Radarsimulationen in dynamischen Umgebungen evaluiert. Das in der Simulation aufgebaute Szenario ist ein offenes Feld mit Asphalt als Boden, wie in Abb. 22 gezeigt. Dabei wurde die Leistungsfähigkeit dieser Techniken bei der Klassifizierung von Fußgängern, Radfahrern und Fahrzeugen unter Verwendung von simulierten, als auch realen Daten bestätigt. Das trainierte CNN-Modell, das einen kombinierten Datensatz aus synthetisch erzeugten und realen Daten nutzt, erwies sich als robuste Lösung und erreichte eine Gesamtgenauigkeit von etwa 94%. Ein besonderes Merkmal dieser Studie war die Einführung der rein synthetischen Generierung des Fahrzeugobjekts.

Arbeitspaket 3.3: Verifizierung des Radars mit einem Radar Target Simulator in Hardware-in-the-Loop (2 PM)

- **Beschreibung/Aufgaben:** Der reale Radarsensor wird in diesem Arbeitspaket in einem Hardware-in-the-Loop (HiL)-Aufbau getestet. Das in Arbeitspaket 3.2 entwickelte Modell wird dabei auf dem Vehicle Radar Test System (VRTS) im Betrieb verifiziert. Die Ergebnisse werden mit den realen Messdaten verglichen, wobei identische Szenarien wie in Arbeitspaket 3.1 verwendet werden. Zusätzlich sollen die VRTS-Messungen auch unter schlechten Witterungsbedingungen durchgeführt werden, um die Realitätsnähe der Simulationsergebnisse zu bewerten.

- **Ergebnisse:** In Arbeitspaket 3.2 wurde ein Regenmodell auf Basis von Gleichung 1 implementiert und in den Vehicle Radar Target Stimulator (VRTS) inte-

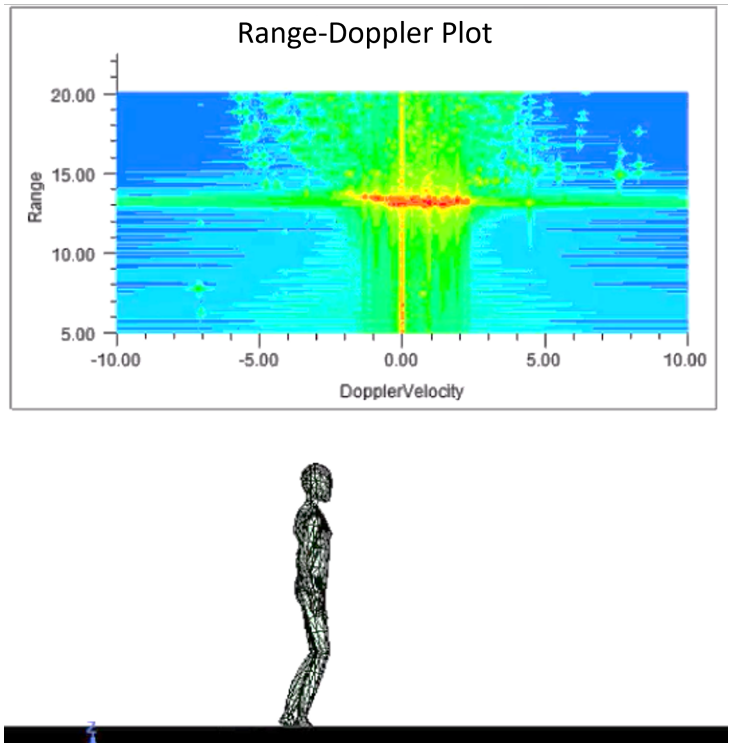


Abbildung 22: Beispiel für ein Range-Doppler-Bild mit Mikro-Doppler-Signalen eines gehenden menschlichen Modells.

griert. Das Modell berechnet die Dämpfungsintensität in Abhängigkeit von der Zielentfernung und der Regenintensität. Zur Simulation weiterer Radareigenschaften wurde CarMaker® von IPG eingesetzt, dessen Radarsimulation Materialeigenschaften sowie Mehrwegeffekte mithilfe von Raytracing berücksichtigt. Zur Demonstration der Radardetektion wurde zusätzlich eine Notbremsfunktion implementiert. Der Versuchsaufbau ist in Abbildung 6 dargestellt. Die Simulationsergebnisse zeigten eine erhöhte Unfallwahrscheinlichkeit bei Regen, wobei die Kritikalität mit zunehmender Fahrzeuggeschwindigkeit und Regenintensität ansteigt.

Arbeitspaket 3.4: Methodik zur Verbesserung der Gated Kamera Ausgaben durch Verwendung eines Radar Referenzsensors (4 PM)

- **Beschreibung/Aufgaben:** In diesem Arbeitspaket wird untersucht, inwiefern der Radarsensor als Referenzquelle zur Verbesserung der Bildqualität von Gated-Kameras beitragen kann. Während leichter Regen und Nebel die Radarmessungen kaum beeinträchtigen, stellen sie für Gated-Kameras eine erhebliche Herausforderung dar. Daher wird analysiert, ob und wie Radarinformationen extrahiert und gezielt genutzt werden können, um kritische Bildbereiche der Gated-Kamera zu verbessern. Ziel ist es, in jenen Entfernungen, in denen der Radar Objekte erkennt, eine gezielte Nachschärfung im Kamerabild zu ermöglichen.

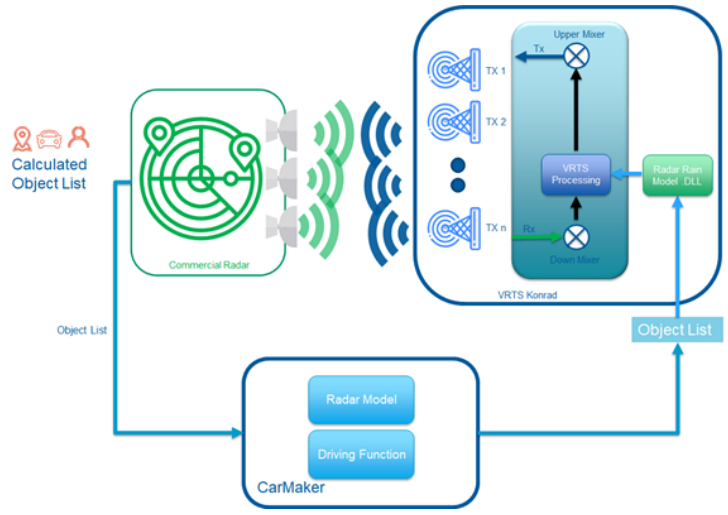


Abbildung 23: Hardware-in-the-Loop Kette mit VRTS

- **Ergebnisse:** Das definierte Testszenario umfasst einen kalibrierten Eckreflektor, ein Forschungsradar sowie ein kommerzielles Radarsystem. Während der Datenerfassung im Regenbereich blieben sowohl die Radarsensoren als auch der Eckreflektor in statischer Position.um die Auswirkungen einer Wasserfilmbildung auf dem Radom zu untersuchen . Der kalibrierte Eckreflektor wurde dabei 3 Meter vertikal oberhalb der getesteten Radarsensoren positioniert. Um den Einfluss metallischer Strukturen auf die Messergebnisse zu minimieren, wurde die gesamte Konstruktion mit radarabsorbierendem Material ausgekleidet. In Abbildung 24 ist kaum eine Abweichung in der Entfernungsmessung erkennbar, was die Eignung des Radars als zuverlässigen Distanzsensor für die Gated-Kamera unter verschiedenen Witterungsbedingungen unterstreicht.

Arbeitspaket 3.5: Vergleich zwischen State-of-the-Art Sensordaten-Fusion von Daimler und THI (4 PM)

- **Beschreibung/Aufgaben:** Im Rahmen des Projekts die Entwicklung eines KI-basierten Fusionsalgorithmus ist geplant. Zur Bewertung von Leistung und Effizienz dieses neu entwickelten Verfahrens ist ein Vergleich mit einem bestehenden Algorithmus erforderlich. Die THI bringt hierzu einen Fusionsalgorithmus ein, der im Rahmen des Projekts MUViT entwickelt wurde. Für den Vergleich werden gezielt kritische Szenarien definiert, die unter unterschiedlichen Witterungsbedingungen getestet werden. Der Fokus liegt dabei auf der Robustheit und Genauigkeit der Algorithmen bei wechselnden Umweltbedingungen. Beide Algorithmen werden unter identischen Testbedingungen mit demselben Sensorsetup ausgewertet, wobei die konkrete Sensorwahl abhängig von der jeweiligen Verfügbarkeit erfolgt.

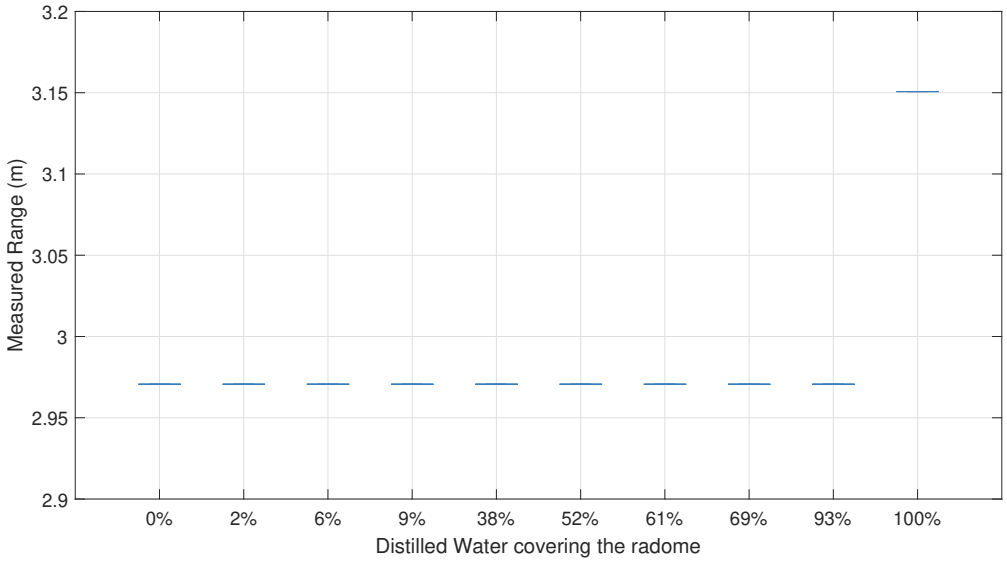


Abbildung 24: Entfernungsmessung des ARS548-Radars in Abhängigkeit von der jeweils auf dem Radom befindlichen Wassermenge.

- **Ergebnisse:** Drei verschiedene Punktwolken-Detektoren wurden mit den Datensätzen ONCE und DBSPRY evaluiert. Zusätzlich wurde eine Analyse des Einflusses von Sprühnebel auf die LiDAR-Detektion durchgeführt. Die Ergebnisse zeigen, dass die Einbindung unseres Datensatzes zu einer deutlichen Steigerung der Erkennungsgenauigkeit aller Modelle im Vergleich zur Baseline führte. Dies unterstreicht die Bedeutung vielfältiger Trainingsszenarien und Objektvariationen.

  Während alle Modelle unter optimalen Bedingungen gute Ergebnisse erzielten, sank ihre Genauigkeit bei Regen- und Sprühbedingungen um etwa 5%. Unter den getesteten Modellen zeigte CenterPoint [57] die beste Leistung und behielt auch bei widrigen Wetterbedingungen eine hohe Genauigkeit bei. PV-RCNN [58] und PointPillar [59] folgten mit ebenfalls überzeugenden Ergebnissen von jeweils über 80 % Genauigkeit. In Fig. 25 die magentafarbenen 3D-Bounding-Boxen markieren die Ground-Truth-Positionen der Zielobjekte, während die grün dargestellten 3D-Bounding-Boxen die vom Modell erkannten Objekte anzeigen. In der ersten Reihe zeigt (a) ein Sprühszenario mit dem Ego-Fahrzeug hinter dem BMW Z4, (b) ein Trocken-Szenario mit derselben Konstellation, (c) ein Trocken-Szenario mit einem Sprinter, der dem Ego-Fahrzeug folgt, (d) ein Sprühszenario mit dem Sprinter hinter dem Ego-Fahrzeug, (e) ein Trocken-Szenario mit dem Ego-Fahrzeug hinter einem Tesla, und (f) ein Sprühszenario mit dem Ego-Fahrzeug hinter einem Tesla, einschließlich einer Fehl-Detektion (False Positive). In der zweiten Reihe zeigen die Bilder (g) bis (i) ONCE-Szenarien mit der Wettermarkierung „regen“, während (j) bis (l) ONCE-Szenarien bei „sonnigem“ Wetter

darstellen.

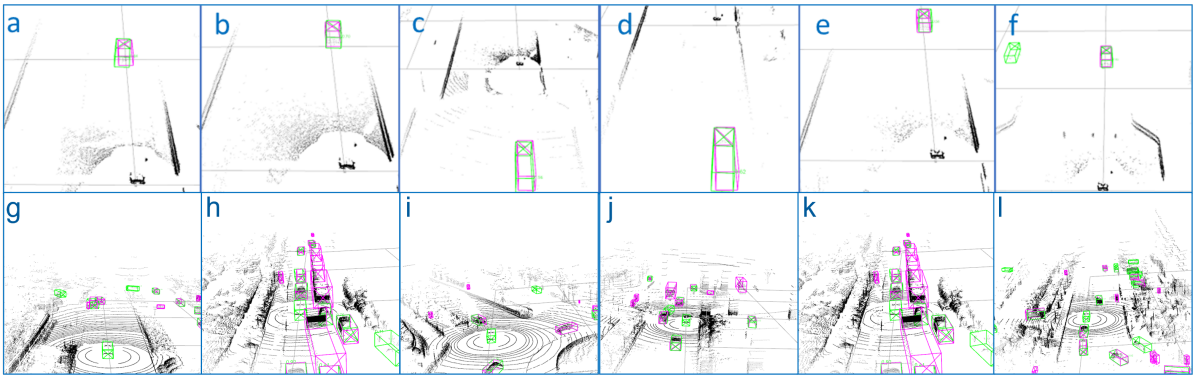


Abbildung 25: DBSPRY-Szenarien mit CenterPoint-Detektion.

Arbeitspaket 3.6: Aufbau eines HiL Demonstrators (2,5 PM)

- **Beschreibung/Aufgaben:** In diesem Arbeitspaket wird ein Hardware-in-the-Loop (HiL)-Demonstrator aufgebaut, um die Ergebnisse des Projekts im Rahmen einer Abschlussdemonstration den Projektpartnern anschaulich zu präsentieren. Dabei werden reale Sensoren in eine Simulationsumgebung eingebunden und mit verschiedenen Methoden stimuliert – unter anderem mit dem Vehicle Radar Test System (VRTS) aus Arbeitspaket 1.3 sowie der Kameraprojektion aus dem Projekt MUViT. So können virtuelle Objekte erzeugt werden, ohne aufwändige reale Testszenarien durchführen zu müssen. Der Demonstrator berücksichtigt nicht nur ideale, sondern auch herausfordernde Witterungsbedingungen wie Regen und Nebel. Ziel ist es, die Funktionsfähigkeit und Verifizierbarkeit der Sensoren im HiL-Aufbau unter realitätsnahen Bedingungen nachzuweisen.
- **Ergebnisse:** In Arbeitspaket 3.1 wurde ein Regenmodell in einen Fahrzeug-Radar-Zielstimulator integriert, das auf einer vordefinierten Gleichung basiert. Dieses Modell berechnet die Dämpfungsintensität in Abhängigkeit von der Entfernung zum Ziel und der Regenintensität. Zur Simulation weiterer Eigenschaften der Radarstrahlung nutzten wir CarMaker® IPG. Die Radarsimulation in diesem Programm berücksichtigt Materialeigenschaften und Mehrfachreflexionen durch Raytracing. Die Elevationswinkel wurden anhand realer Messungen justiert. Der Radarstimulator wurde mit einem Roboter-3D-Arm kombiniert, um Azimut- und Elevationswinkel zu berücksichtigen. Die Schnittstelle zwischen CarMaker und dem Hardware-in-the-Loop (HIL) Prüfstand wurde mit der von ASAM veröffentlichten OSI-Schnittstelle entwickelt. Zusätzlich entwickelten wir eine Notbremsfunktion, um die Radardetektion zu demonstrieren, deren Aufbau in Diagramm 26 dargestellt ist. Die Ergebnisse zeigen, dass die Unfallhäufigkeit bei Regen zunimmt, wobei die Kritikalität mit der Fahrzeuggeschwindigkeit und der Regenintensität steigt. Das gesamte Tool wurde in Veristand von NI implementiert.

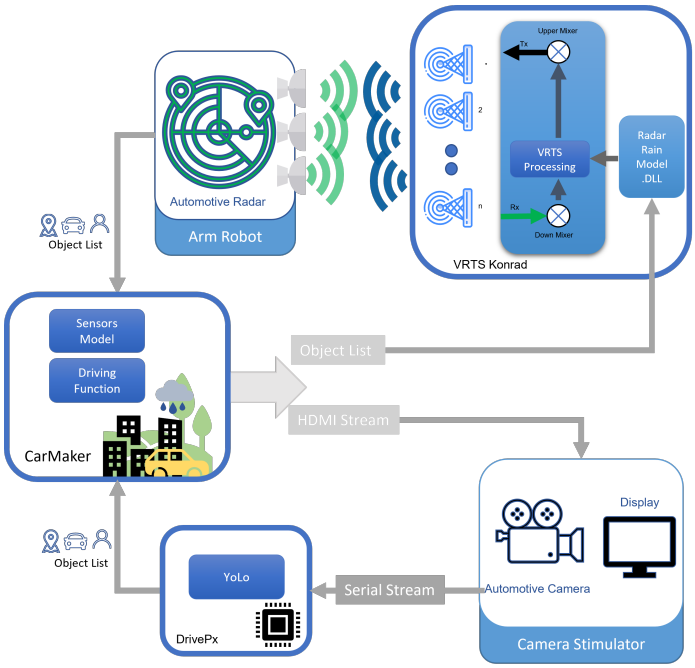


Abbildung 26: Hardware-in-the-Loop Kette

Carmaker wird durch eine benutzerdefinierte Bibliothek für die Echtzeitverarbeitung aktiviert. Der Radar-Stimulator wird über eine CAN-Schnittstelle betrieben, und das Radar-Störmodell wurde als Echtzeitbibliothek kompiliert und dem Setup hinzugefügt.

Arbeitspaket 3.7: Aufbau des LIDAR Demonstrators (3,5 PM)

- **Beschreibung/Aufgaben:** Bisher wurden die Sensoren ausschließlich in statischen Szenarien untersucht. In diesem Arbeitspaket wird ein Demonstrator aufgebaut, der die Erprobung in dynamischen Szenarien ermöglicht, mit Fokus auf den LiDAR-Sensor. Da LiDAR-Systeme besonders empfindlich auf widrige Wetterbedingungen reagieren, steht ihre Leistungsbewertung im Vordergrund. Zum Einsatz kommt ein Solid-State-LiDAR der Firma Ibeo, der in ein Versuchsfahrzeug integriert wird. Ziel ist es, die Funktionsfähigkeit und Robustheit des Systems unter anspruchsvollen Witterungsbedingungen zu evaluieren und zu verifizieren. Während der Testfahrten werden sowohl LiDAR-Daten als auch Ground-Truth-Daten aufgezeichnet, um eine detaillierte Analyse im Nachgang zu ermöglichen. Der Demonstrator dient somit der gezielten Bewertung der Sensorleistung im realitätsnahen Einsatz unter schlechten Umweltbedingungen.

- **Ergebnisse:** In Arbeitspaket 1.4 wird das Potenzial des Radars als Referenzsensor zur Verbesserung der Bildqualität einer Gated-Kamera untersucht. Während leichter Regen und Nebel die Radarmessungen nur minimal beeinflussen, können diese Witterungsbedingungen die Bildqualität der Gated-Kamera erheblich

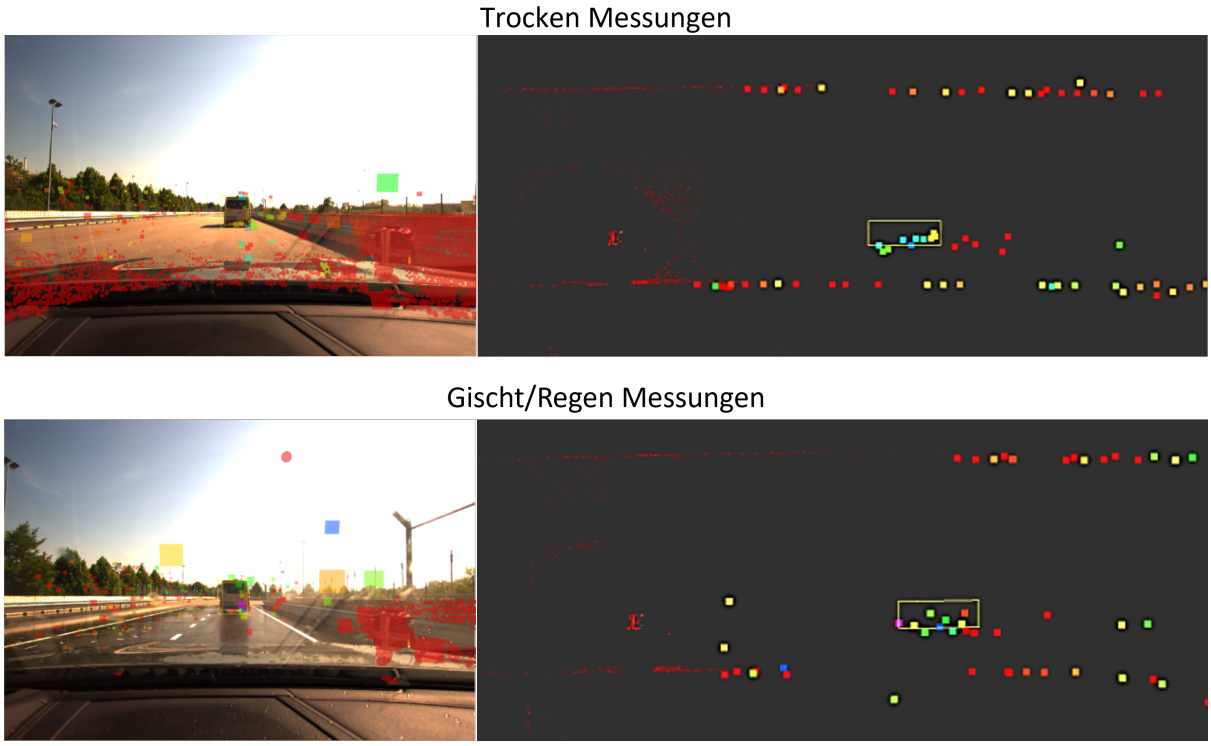


Abbildung 27: Beispiel einer Radar- und Lidardetektion in klaren und schlechten Witterungsbedingungen.

beeinträchtigen. Daher wird geprüft, inwieweit Radarinformationen zur Kompensation dieser Einschränkungen beitragen können.

Abbildung 27 verdeutlicht, dass das LiDAR-Signal durch Wassertröpfchen gestört oder sogar blockiert wird. Diese reflektieren und streuen Teile des Lasersignals, was zu einer Verschlechterung der Sensordaten und der Zielerkennung führt. Im Gegensatz dazu bleibt die Detektionsfähigkeit des Radars auch bei Regen weitgehend erhalten, was es zu einem geeigneten Referenzsensor für solche Bedingungen macht.

2.2 Erläuterung der wichtigsten Positionen im zahlenmäßigen Nachweis

Der größte Budgetposten des Projekts entfiel planmäßig auf die Personalkosten, bedingt durch den Einsatz von drei wissenschaftlichen Mitarbeitern, die zur Umsetzung der Projektziele die einzelnen Arbeitspakete bearbeitet haben. Die Anschaffungen im Rahmen der Geräteliste wurden im Projektverlauf entsprechend umgesetzt und an neue Erkenntnisse sowie Erfordernisse angepasst. Nach Genehmigung der Änderungsanträge erfolgte die Beschaffung stets unter Berücksichtigung von Nachhaltigkeit und Wirtschaftlichkeit.

2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

Alle Arbeitspakete wurden im vorgesehenen Zeit- und Kostenrahmen abgeschlossen. Verzögerungen traten hauptsächlich im ersten Projektjahr aufgrund der COVID-19-Pandemie auf, hatten jedoch keinen wesentlichen Einfluss auf die Projektergebnisse. Die ersten Konsortialtreffen fanden online statt, wodurch der persönliche Austausch nicht stattfand. Zudem konnten in diesem Zeitraum zahlreiche Konferenzteilnahmen nicht stattfinden. Die Planung des Gischt-Simulators erwies sich als komplexer als erwartet und erforderte mehr Zeit. Daher wurde das Konzept vereinfacht, um die nachfolgenden Arbeitspakete trotz der Verzögerung vollständig umsetzen zu können.

2.4 Voraussichtlicher Nutzen und Verwertbarkeit des Ergebnisses (Fortschreibung des Verwertungsplanes)

2.4.1 ANSYS

ANSYS konnte in Zusammenarbeit mit der THI wertvolle Erkenntnisse zur Schlechtwettersimulation von Regen und Nebel gewinnen und diese mit Realdaten aus der CARISSMA-Versuchshalle validieren. Die Kooperation wurde im Rahmen des Projekts weiter intensiviert, wodurch zahlreiche gewinnbringende Diskussionen entstanden. Auf Basis der erzielten Ergebnisse sind weitere gemeinsame Projekte geplant, um die gewonnenen Erkenntnisse weiter zu vertiefen.

2.4.2 Fifty2

Fifty2 konnte in Zusammenarbeit mit ANSYS seine Partikel-Solver-Technologie nutzen, um hochpräzise Verteilungen von Regen und Nebel bereitzustellen. Die enge Kooperation bei der Simulation der CARISSMA-Halle und der Nachbildung von Versuchen hat das gemeinsame Verständnis der Schlechtwettereinflüsse und der erforderlichen Parameter für realistische Simulationen erheblich vertieft. Zudem wurden die durchgeführten Spray-Versuche in der Simulation nachgestellt, wodurch sowohl die Möglichkeiten als auch die Grenzen der aktuellen Software sichtbar wurden. Weitere gemeinsame Projekte mit Fifty2 sind geplant, um an die erzielten Forschungsergebnisse anzuknüpfen.

2.4.3 THI

Durch das Projekt konnte die THI ihre Forschungsfelder in den Bereichen Schlechtwetter-Simulation, Gischt-Erzeugung und Witterungseinflüsse auf Radarsysteme weiter vertiefen. Ein an der THI verfügbarer Gischt-Simulator ermöglicht künftig die Validierung von Sensoren in weiteren Projekten. Zudem wurde ein Radar-Target-Simulator entwickelt, der simulierte Schlechtwettermodelle nutzt, um Radarziele realistisch darzustellen. Die entwickelten KI-Algorithmen zur Augmentierung von Klarwetterdaten

mit Schlechtwettereffekten eröffnen ein neues Forschungsfeld am Institut und bieten großes Potenzial für die Absicherung kamerabasierter Fahrfunktionen.

2.5 Fortschritte auf dem Gebiet des Vorhabens bei anderen Stellen während der Durchführung

Die Forschung zu den Auswirkungen ungünstiger Wetterbedingungen auf die Sensorik von Assistenzsystemen und automatisierten Fahrzeugen ist bislang noch begrenzt. Während der Projektlaufzeit gewann das Thema jedoch zunehmend an Bedeutung und wurde stärker in die Forschungslandschaft integriert. Die Projektpartner ANSYS und Fifty2 konnten ihre Simulationen erheblich verbessern und diese mit realen, an der THI aufgezeichneten Daten validieren. Die enge Zusammenarbeit zwischen Forschung und Industrie erwies sich als besonders wertvoll, da Projektergebnisse direkt in die entwickelte Software einflossen und somit auch für Serienprodukte genutzt werden können.

2.6 Geplante und erfolgte Veröffentlichungen im Rahmen des Vorhabens

Im Projektzeitraum wurden 11 Veröffentlichungen (peer-review) in international Fachkonferenzen eingereicht. Zudem wurde eine Dissertation im Projektzeitraum abgeschlossen, eine weitere steht kurz vor Abschluss. Im Folgenden eine Auflistung aller veröffentlichten Artikel:

- [9] **Simulation and Validation of Automotive Radar Performance with Water Spray over Radome**. Wachtel, Diogo and Rothmeier, Thomas and Cristófoli Duarte, Letícia and Vossiek, Martin and Huber, Werner. 2024 IEEE Sensors. Kobe, Japan
- [10] **Simulation and Validation of Automotive Radar Performance with Water Spray over Radome**. Wachtel, Diogo and Rothmeier, Thomas and Cristófoli Duarte, Letícia and Vossiek, Martin and Huber, Werner. 2024 IEEE Sensors. Kobe, Japan
- [21] **Simulation and Validation of Automotive Radar Performance with Water Spray over Radome**. Wachtel, Diogo and Rothmeier, Thomas and Cristófoli Duarte, Letícia and Vossiek, Martin and Huber, Werner. 2024 IEEE Sensors. Kobe, Japan
- [22] **Simulation and Validation of Automotive Radar Performance with Water Spray over Radome**. Wachtel, Diogo and Rothmeier, Thomas and Cristófoli Duarte, Letícia and Vossiek, Martin and Huber, Werner. 2024 IEEE Sensors. Kobe, Japan

- [60] **Simulation and Validation of Automotive Radar Performance with Water Spray over Radome**. Wachtel, Diogo and Rothmeier, Thomas and Cristófoli Duarte, Letícia and Vossiek, Martin and Huber, Werner. 2024 IEEE Sensors. Kobe, Japan
- [61] **Exploring Synthetic Radar Data and Deep Learning for Road User Classification in Autonomous Vehicles**. Wachtel, Diogo and Tasabat, Sinan and Rothmeier, Thomas and Cristófoli, Leticia and Huber, Werner. 2024 IEEE 27th International Conference on Intelligent Transportation Systems. Edmonton, Canada
- [62] **Navigating on Adverse Weather: Enhancing LiDAR-Based Detection with the DBSPRY Dataset**. Wachtel, Diogo and Derder, Heitor and Rothmeier, Thomas and Nassu, Bogdan and Huber, Werner. 2024 IEEE 27th International Conference on Intelligent Transportation Systems. Edmonton, Canada
- [63] **Evaluation of Automotive Radar Simulation Tools for Adverse Weather Conditions: A Comparative Analysis of Real Measurement, HFSS and Monte-Carlo GO Methods**. Wachtel, Diogo and Schuessler, Christian and von dem Bussche, Tetmar and Rothmeier, Thomas and Vossiek, Martin and Huber, Werner. 2024 IEEE Radar Conference (RadarConf24). Denver, USA
- [64] **Radar in the Rain: Understanding and Simulating Environmental Effects on ADAS Radar Sensors**. Wachtel, Diogo and Rothmeier, Thomas and von dem Bussche, Tetmar and Huber, Werner and Vossiek, Martin. 2024 IEEE Radar Conference (RadarConf24). Denver, USA
- [65] **A novel Conditional Generative Adversarial Networks for Automotive Radar Range-Doppler Targets Synthetic Generation**. Wachtel, Diogo and Queiroz, Samuel and Schön, Torsten and Huber, Werner and Faria, Lester. 2023 IEEE 26th International Conference on Intelligent Transportation Systems (ITSC). Bilbao, Spain
- [66] **Convolutional Neural Network Classification of Vulnerable Road Users based on Micro-Doppler Signatures using an Automotive Radar**. Wachtel, Diogo and Edler, Johannes and Schröder, Sabine and Queiroz, Samuel and Huber, Werner. 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC). Macau, China

2.6.1 Liste der im Projektzeitraum erfolgten Abschlussarbeiten

- **T. Yavuz** Erkennbarkeit von Gischt mittels Umfeldsensorik, 2023
- **C. Bakka** Estimation and Analysis of Target's Height Using Automotive Radars, 2022

2.6.2 Liste der im Projektzeitraum erfolgten Studentenprojekte

- **Sommersemester 2023:** KI-basierte Synthetisierung von Gischt auf Kameradaten
- **Sommersemester 2022:** Erkennbarkeit von Gischt mittels Umfeldsensorik
- **Sommersemester 2023:** KI-basierte Detektion- und Klassifikationsmethoden für Automotive Sensoren
- **Sommersemester 2024:** Generierung von Mikrodoppler Daten mit GANs

2.6.3 Liste der im Projektzeitraum erfolgten Vorträge

- **Automotive Radar unter ungünstigen Wetterbedingungen:** 3. VDI Fachkonferenz Umfelderfassung im Fahrzeug 2023, Sensorik – Software – KI – Simulation – Absicherung –Testing – Validierung. Wachtel, Diogo. Nürtingen, Germany
- **Synthetic Sensor Data in Adverse Weather Conditions:** BayWISS Netzwerktreffen bei Airbus 2023
- **Radar under rain:** PhD Tag an der Technische Hochschule Ingolstadt 2023
- **Swapping Autoencoder zur Parametrisierung der Intensität von KI-generierten Schlechtwetterdaten:** PhD Tag an der Technische Hochschule Ingolstadt 2023

3. Kurzfassung/Berichtsblatt

Siehe Anlage.

4. Erfolgskontrollbericht

Siehe Anlage.

Literatur

[1] E. Shearman, E. G. Hoare, and A. Hutton, “Trials of automotive radar and lidar performance in road spray,” in *IEE Colloquium on Automotive Radar and Navigation Techniques (Ref. No. 1998/230)*. IET, 1998, pp. 10–1.

[2] NHTSA, “Update on the status of splash and spray suppression technology for large trucks,” 2000, more about suppression system review.

[3] Y. Zhao, R. Wu, and H. Dong, “Unpaired Image-to-Image Translation Using Adversarial Consistency Loss,” in *Computer Vision – ECCV 2020*, 2020.

[4] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, “Generative Adversarial Nets,” in *Advances in Neural Information Processing Systems*, 2014.

[5] S. H. und A. Riener, “A general approach for simulating rain effects on sensor data in real and virtual environments,” *IEEE Transactions on Intelligent Vehicles*, 2019.

[6] T. E. und A. Prinz und L. Brabetz und E. Biebl, “Szenarienbasiertevalidierung eines hybriden radarmodells für test und absicherungautomatisierter fahrfunktionen,” *IEEE Transactions on Intelligent Vehicles*, 2019.

[7] S. O. Wald and F. Weinmann, “Ray tracing for range-doppler simulation of 77 ghz automotive scenarios,” in *2019 13th European Conference on Antennas and Propagation (EuCAP)*, 2019, pp. 1–4.

[8] C. Schüßler, M. Hoffmann, J. Bräunig, I. Ullmann, R. Ebelt, and M. Vossiek, “A realistic radar ray tracing simulator for large mimo-arrays in automotive environments,” *IEEE Journal of Microwaves*, vol. 1, no. 4, pp. 962–974, 2021.

[9] T. Rothmeier and W. Huber, “Let it Snow: On the Synthesis of Adverse Weather Image Data,” in *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*, 2021.

[10] T. Rothmeier, D. Wachtel, T. von Dem Bussche-Hünnefeld, and W. Huber, “I Had a Bad Day: Challenges of Object Detection in Bad Visibility Conditions,” in *2023 IEEE Intelligent Vehicles Symposium (IV)*, 2023.

[11] P. Sun, H. Kretzschmar, X. Dotiwalla, A. Chouard, V. Patnaik, P. Tsui, J. Guo, Y. Zhou, Y. Chai, B. Caine, V. Vasudevan, W. Han, J. Ngiam, H. Zhao, A. Timofeev, S. Ettinger, M. Krivokon, A. Gao, A. Joshi, Y. Zhang, J. Shlens, Z. Chen, and D. Anguelov, “Scalability in Perception for Autonomous Driving: Waymo Open Dataset,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020.

[12] H. Caesar, V. Bankiti, A. H. Lang, S. Vora, V. E. Liong, Q. Xu, A. Krishnan, Y. Pan, G. Baldan, and O. Beijbom, “nuScenes: A Multimodal Dataset for Autonomous Driving,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020.

[13] M. A. Kenk and M. Hassaballah, “DAWN: Vehicle Detection in Adverse Weather Nature Dataset,” *arXiv preprint arXiv:2008.05402*, 2020.

[14] C. Sakaridis, D. Dai, and L. Van Gool, “ACDC: The Adverse Conditions Dataset With Correspondences for Semantic Driving Scene Understanding,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2021.

[15] T. Park, A. A. Efros, R. Zhang, and J.-Y. Zhu, “Contrastive Learning for Unpaired Image-to-Image Translation,” in *Computer Vision – ECCV 2020*, ser. Lecture Notes in Computer Science, 2020.

[16] F. Luan, S. Paris, E. Shechtman, and K. Bala, “Deep Photo Style Transfer,” in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017.

[17] J. Yoo, Y. Uh, S. Chun, B. Kang, and J.-W. Ha, “Photorealistic Style Transfer via Wavelet Transforms,” *arXiv:1903.09760 [cs]*, 2019.

[18] R. Rombach, A. Blattmann, D. Lorenz, P. Esser, and B. Ommer, “High-Resolution Image Synthesis With Latent Diffusion Models,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022.

[19] T. Park, J.-Y. Zhu, O. Wang, J. Lu, E. Shechtman, A. Efros, and R. Zhang, “Swapping Autoencoder for Deep Image Manipulation,” in *Advances in Neural Information Processing Systems*, 2020.

[20] L. Zhang, A. Rao, and M. Agrawala, “Adding Conditional Control to Text-to-Image Diffusion Models,” in *2023 IEEE/CVF International Conference on Computer Vision (ICCV)*, 2023.

[21] T. Rothmeier, W. Huber, and A. C. Knoll, “Time To Shine: Fine-Tuning Object Detection Models With Synthetic Adverse Weather Images,” in *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, 2024.

[22] T. Rothmeier, M. D. V. Hoger, B. T. Nassu, W. Huber, and A. C. Knoll, “Out of the Box: Weather Augmentation for Enhanced Detection in Bad Visibility Conditions,” *2024 IEEE International Intelligent Transportation Systems Conference (ITSC)*, 2025.

[23] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *arXiv preprint arXiv:1506.01497*, 2016.

[24] Z. Tian, C. Shen, H. Chen, and T. He, “FCOS: Fully Convolutional One-Stage Object Detection,” in *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 2019.

[25] D. Wachtel, T. Rothmeier, T. von dem Bussche, W. Huber, and M. Vossiek, “Radar in the rain: Understanding and simulating environmental effects on adas radar sensors,” in *2024 IEEE Radar Conference (RadarConf24)*, 2024, pp. 1–6.

[26] P. Isola, J.-Y. Zhu, T. Zhou, and A. A. Efros, “Image-To-Image Translation With Conditional Adversarial Networks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017.

[27] X. Huang, M.-Y. Liu, S. Belongie, and J. Kautz, “Multimodal Unsupervised Image-to-Image Translation,” in *Computer Vision – ECCV 2018*, 2018.

[28] E. Thorn, S. C. Kimmel, M. Chaka, Virginia Tech Transportation Institute, Southwest Research Institute, and Inc. Booz Allen Hamilton, “A Framework for Automated Driving System Testable Cases and Scenarios,” Tech. Rep., 2018.

[29] F. Yu, H. Chen, X. Wang, W. Xian, Y. Chen, F. Liu, V. Madhavan, and T. Darrell, “BDD100K: A Diverse Driving Dataset for Heterogeneous Multitask Learning,” in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020.

[30] M. Bijelic, T. Gruber, F. Mannan, F. Kraus, W. Ritter, K. Dietmayer, and F. Heide, “Seeing Through Fog Without Seeing Fog: Deep Multimodal Sensor Fusion in Unseen Adverse Weather,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020.

[31] M.-F. Chang, J. Lambert, P. Sangkloy, J. Singh, S. Bak, A. Hartnett, D. Wang, P. Carr, S. Lucey, D. Ramanan, and J. Hays, “Argoverse: 3D Tracking and Forecasting With Rich Maps,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019.

[32] M. Heusel, H. Ramsauer, T. Unterthiner, B. Nessler, and S. Hochreiter, “GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium,” in *Advances in Neural Information Processing Systems*, 2017.

[33] R. Zhang, P. Isola, A. A. Efros, E. Shechtman, and O. Wang, “The Unreasonable Effectiveness of Deep Features as a Perceptual Metric,” in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018.

[34] C. H. Wu and F. De la Torre, “A Latent Space of Stochastic Diffusion Models for Zero-Shot Image Editing and Guidance,” in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2023.

[35] N. Tumanyan, M. Geyer, S. Bagon, and T. Dekel, “Plug-and-Play Diffusion Features for Text-Driven Image-to-Image Translation,” in *2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2023.

[36] T.-J. Fu, W. Hu, X. Du, W. Y. Wang, Y. Yang, and Z. Gan, “Guiding Instruction-based Image Editing via Multimodal Large Language Models,” in *International Conference on Learning Representations (ICLR)*, 2024.

[37] D. Podell, Z. English, K. Lacey, A. Blattmann, T. Dockhorn, J. Müller, J. Penna, and R. Rombach, “SDXL: Improving Latent Diffusion Models for High-Resolution Image Synthesis,” in *The Twelfth International Conference on Learning Representations*, 2023.

[38] Zhou Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, “Image quality assessment: From error visibility to structural similarity,” *IEEE Transactions on Image Processing*, 2004.

[39] A. Radford, J. W. Kim, C. Hallacy, A. Ramesh, G. Goh, S. Agarwal, G. Sastry, A. Askell, P. Mishkin, J. Clark, G. Krueger, and I. Sutskever, “Learning Transferable Visual Models From Natural Language Supervision,” in *Proceedings of the 38th International Conference on Machine Learning*, 2021.

[40] M. Oquab, T. Darcet, T. Moutakanni, H. V. Vo, M. Szafraniec, V. Khalidov, P. Fernandez, D. Haziza, F. Massa, A. El-Nouby, M. Assran, N. Ballas, W. Galuba, R. Howes, P.-Y. Huang, S.-W. Li, I. Misra, M. Rabbat, V. Sharma, G. Synnaeve, H. Xu, H. Jegou, J. Mairal, P. Labatut, A. Joulin, and P. Bojanowski, “DINOv2: Learning Robust Visual Features without Supervision,” *Transactions on Machine Learning Research*, 2023.

[41] J. F. Strange, R. K. Heffley, and D. H. Weir, “Reduction of adverse aerodynamic effects of large trucks,” 1978.

[42] J. Tromp, “Splash and spray by lorries,” 1985.

[43] A. P. Gaylard, K. Kirwan, and D. A. Lockerby, “Surface contamination of cars: A review,” pp. 1160–1176, 8 2017.

[44] T. Hagemeier, M. Hartmann, and D. Thévenin, “Practice of vehicle soiling investigations: A review,” pp. 860–875, 10 2011.

[45] J. Jilesen, A. Gaylard, and J. Escobar, “Numerical investigation of features affecting rear and side body soiling,” *SAE International Journal of Passenger Cars - Mechanical Systems*, vol. 10, pp. 299–308, 2017.

[46] A. Kabanovs, A. Garmory, M. Passmore, and A. Gaylard, “Investigation into the dynamics of wheel spray released from a rotating tyre of a simplified vehicle model,” *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 184, pp. 228–246, 1 2019.

[47] D. Forbes, G. Page, M. Passmore, and A. Gaylard, “A study of computational methods for wake structure and base pressure prediction of a generic suv model

with fixed and rotating wheels," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 231, pp. 1222–1238, 8 2017.

[48] X. Hu, L. Liao, Y. Lei, H. Yang, Q. Fan, B. Yang, J. Chang, and J. Wang, "A numerical simulation of wheel spray for simplified vehicle model based on discrete phase method," *Advances in Mechanical Engineering*, vol. 7, pp. 1–8, 7 2015.

[49] V. Strohbücker, R. Niesner, and F. Joos, "Simulation method for vehicle tire water spraying behavior," in *18. Internationales Stuttgarter Symposium*, M. Bargende, H.-C. Reuss, and J. Wiedemann, Eds. Wiesbaden: Springer Fachmedien Wiesbaden, 2018, pp. 1393–1409.

[50] G. W. Williams, B. Gibbons, R. Viner, and H. Flintsch, "Assessment of impact of splash and spray on road users: Results of controlled experiment." *Transportation Research Record*, pp. 151–160, 2012.

[51] J. V. Rivero, T. Gerbich, B. Buschardt, and J. Chen, "The effect of spray water on an automotive lidar sensor: A real-time simulation study," *IEEE Transactions on Intelligent Vehicles*, vol. 7, pp. 57–72, 3 2022.

[52] S. Walz, "A benchmark for spray from nearby cutting vehicles," *IEEE International Intelligent Transportation Systems Conference (ITSC)*, 2021.

[53] Y. C. Shih, W. H. Liao, W. C. Lin, S. K. Wong, and C. C. Wang, "Reconstruction and synthesis of lidar point clouds of spray," *IEEE Robotics and Automation Letters*, vol. 7, pp. 3765–3772, 4 2022.

[54] C. Linnhoff, D. Scheuble, M. Bijelic, L. Elster, P. Rosenberger, W. Ritter, D. Dai, and H. Winner, "Simulating road spray effects in automotive lidar sensor models," *arXiv preprint arXiv:2212.08558*, 2022.

[55] S. Hasirlioglu and A. Riener, "A General Approach for Simulating Rain Effects on Sensor Data in Real and Virtual Environments," *IEEE Transactions on Intelligent Vehicles*, 2019.

[56] R. Gourova, O. Krasnov, and A. Yarovoy, "Analysis of rain clutter detections in commercial 77 ghz automotive radar," in *2017 European Radar Conference (EURAD)*, 2017, pp. 25–28.

[57] T. Yin, X. Zhou, and P. Krähenbühl, "Center-based 3D object detection and tracking," *CVPR*, 2021.

[58] S. Shi, C. Guo, L. Jiang, Z. Wang, J. Shi, X. Wang, and H. Li, "PV-RCNN: Point-Voxel Feature Set Abstraction for 3D Object Detection," in *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020, pp. 10 526–10 535.

[59] A. H. Lang, S. Vora, H. Caesar, L. Zhou, J. Yang, and O. Beijbom, "PointPillars: Fast encoders for object detection from point clouds," in *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019, pp. 12 689–12 697.

[60] D. Wachtel, T. Rothmeier, L. Cristofoli, M. Vossiek, and W. Huber, "Simulation and Validation of Automotive Radar Performance with Water Spray Over Radome," in *2024 IEEE SENSORS*, 2024.

[61] D. Wachtel, T. Rothmeier, S. Tasabat, L. Cristofoli, and W. Huber, "Exploring Synthetic Radar Data and Deep Learning for Road User Classification in Autonomous Vehicles," in *IEEE 27th International Conference on Intelligent Transportation Systems*, 2024.

[62] D. Wachtel, H. Derder, T. Rothmeier, B. Nassu, and W. Huber, "Navigating on Adverse Weather: Enhancing LiDAR-Based Detection with the DBSPRY Dataset," in *IEEE 27th International Conference on Intelligent Transportation Systems*, 2024.

[63] D. Wachtel, C. Schuessler, T. von dem Bussche, T. Rothmeier, M. Vossiek, and W. Huber, "Evaluation of Automotive Radar Simulation Tools for Adverse Weather Conditions: A Comparative Analysis of Real Measurement, HFSS and Monte-Carlo GO Methods," in *2024 IEEE Radar Conference (RadarConf24)*, 2024.

[64] D. Wachtel, T. Rothmeier, T. von dem Bussche, W. Huber, and M. Vossiek, "Radar in the Rain: Understanding and Simulating Environmental Effects on ADAS Radar Sensors," in *2024 IEEE Radar Conference (RadarConf24)*, 2024.

[65] D. Wachtel, S. Queiroz, T. Schön, W. Huber, and L. Faria, "A novel Conditional Generative Adversarial Networks for Automotive Radar Range-Doppler Targets Synthetic Generation," in *2023 IEEE 26th International Conference on Intelligent Transportation Systems (ITSC)*, 2023.

[66] D. Wachtel, J. Edler, S. Schröder, S. Queiroz, and W. Huber, "Convolutional Neural Network Classification of Vulnerable Road Users based on Micro-Doppler Signatures using an Automotive Radar," in *2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*, 2022.