

Kooperative Absichtserkennung mittels maschineller Lernverfahren – Radfahrerschutz im Kontext des hochautomatisierten Fahrens ¹

Maarten Bieshaar²

Abstract: Das Radfahren wird im Verkehr der Zukunft eine zentrale Rolle spielen. Um Unfälle zu vermeiden, ist es entscheidend, Radfahrer frühzeitig zu erkennen und deren Absichten vorherzusagen. Fahrzeuge, die mit Sensoren, Datenverarbeitungssystemen und Kommunikationsfähigkeiten ausgestattet sind, erstellen und pflegen ein lokales Modell ihrer Verkehrsumgebung. Gruppen von kooperierenden und interagierenden Fahrzeugen, sowie Roadside Units, und Radfahrer, die mit Smart Devices (z.B. Smartphone und Smartwatch) und anderen am Körper getragenen Sensoren ausgestattet sind, tauschen Informationen aus. Sie bilden ein multimodales Sensorsystem mit dem Ziel, Radfahrer und deren Absichten zuverlässig zu erfassen. Die kollektive Intelligenz aller Verkehrsteilnehmer erlaubt es den Wahrnehmungshorizont der einzelnen Verkehrsteilnehmer über deren eigene sensorische Fähigkeiten hinaus zu erweitern und somit eine bessere Erkennung der Absichten von Radfahrer zu ermöglichen.³

1 Einführung

1.35 Millionen Verkehrstote pro Jahr wurde in der Ausgabe 2018 des von der Weltgesundheitsorganisation veröffentlichten globalen Statusberichts zur Verkehrssicherheit gemeldet [Wo18]. Darüber hinaus erleiden schätzungsweise 20 bis 50 Millionen weitere Menschen nicht-tödliche Verletzungen, welche zumeist in einer dauerhaften Behinderung enden. Ungeschützte Verkehrsteilnehmer (engl. Vulnerable Road Users, kurz VRU), d.h. Radfahrer und Fußgänger sind besonders gefährdet, da sie über kein passives Sicherheitssystem verfügen, das die Auswirkungen von Unfällen potenziell abmildern könnte. In den vergangenen Jahren haben sich zahlreiche Bürgerinitiativen für eine „Verkehrswende“ und damit für die Förderung des nachhaltigen und klimafreundlichen Radverkehrs starkgemacht. Obwohl die ersten Erfolge zu verzeichnen sind (d.h., dem Radverkehr wird in vielen Städten mehr Raum zugestanden) bleibt das Radfahren auf deutschen Straßen weiterhin gefährlich. 2019 starben auf deutschen Straßen im Durchschnitt 1 – 2 Radfahrer pro Tag.

Moderne Fahrerassistenzsysteme, wie bspw. automatische Warnassistenten, können die Sicherheit von ungeschützten Verkehrsteilnehmern, z.B. durch eine frühzeitige Warnung

¹ Englischer Titel der Dissertation: „Cooperative Intention Detection using Machine Learning – Advanced Cyclist Protection in the Context of Automated Driving“

² Universität Kassel, Intelligente Eingebettete Systeme, Kassel, Deutschland, mbieshaar@uni-kassel.de

³ Aus Gründen der Lesbarkeit wird im Text die männliche Form verwendet, nichtsdestoweniger beziehen sich die Angaben auf Angehörige aller Geschlechter.

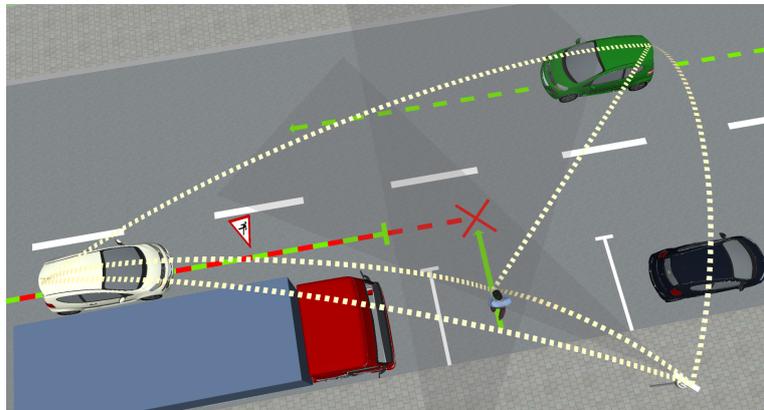


Abb. 1: Schematische Darstellung einer kritischen Situation aus [Bi21]. Ein Fußgänger möchte die Straße kreuzen, wobei er durch einen LKW verdeckt wird. Die Situation wird durch die Kooperation (angedeutet durch die gestrichelten gelben Pfeile) und Informationsaustausch zwischen den Fahrzeugen, der RSU und dem Smartphone, das der Fußgänger bei sich trägt, aufgelöst.

deutlich erhöhen. Diese Systeme prognostizieren die Absicht von ungeschützten Verkehrsteilnehmern, d.h. die geplante, aber noch nicht ausgeführte Aktion, basierend auf lokal verfügbaren sensorischen Informationen. Moderne (sowie in Zukunft auch hoch-automatisierte) Fahrzeuge sind mit zahlreichen Sensoren ausgestattet, u.a. Kameras, LiDAR und RADAR. Dennoch kann es infolge einer Verdeckung (z.B. Radfahrer befindet sich im toten Winkel) oder einer Fehlfunktion der Sensorik stets zu gefährlichen und bisweilen sogar tödlichen Situationen kommen. Fehler, insbesondere in der maschinellen Wahrnehmung, haben zumeist eine gravierende Beeinträchtigung des Gesamtsystems zur Folge. Kommunikation und Kooperation mit anderen Verkehrsteilnehmern und mit Sensoren ausgestatteter Infrastruktur (engl. Roadside Unit, kurz RSU) stellt eine Möglichkeit dar Komplettausfälle des eigenen Wahrnehmungssystems zu kompensieren und mit Verdeckungen umzugehen.

Die der Arbeit zu Grunde liegende Vision des zukünftigen kooperative-interagierenden, hoch-automatisierten und vor allem sicheren Verkehrs lässt sich am folgenden Beispiel erläutern [Bi17]. Ein Fußgänger, der hinter einem Hindernis die Straße überquert, ist in Abb. 1 dargestellt. Das herannahende weiße Fahrzeug kann den verdeckten Fußgänger und seine Absicht, die Straße zu überqueren, nicht rechtzeitig erfassen. Das entgegenkommende Fahrzeug und eine RSU (hier illustriert durch eine Überwachungskamera) können jedoch den Fußgängern und dessen Absicht erkennen. Diese erkannte Absicht kann dem weißen Fahrzeug via moderner drahtloser Car2X-Kommunikation mitgeteilt werden, so dass der Fahrer oder das Fahrzeug selbst (im Falle des automatisierten Fahrens) eine Notbremsung einleiten kann. Eine weitere Informationsquelle sind die vom Fußgänger bei sich getragene Smart Devices, z.B. ein Smartphone, eine Smartwatch oder andere Wearables. Es wird demnach die kollektive Intelligenz aller Fahrzeuge, der RSU sowie der vom Fußgänger bei sich getragenen Smart Devices genutzt, um die Absicht des Fußgängers, die Straße zu überqueren, zu erkennen.

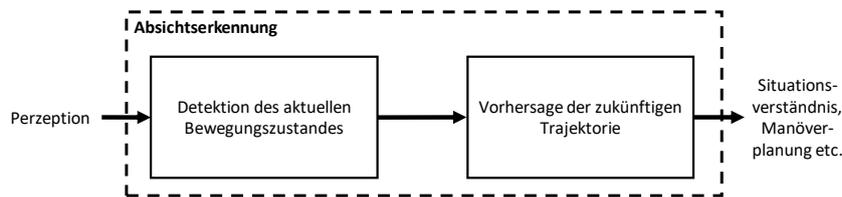


Abb. 2: Schematische Darstellung des zweistufigen Prozesses zur Absichtserkennung: Detektion des aktuellen Bewegungszustandes gefolgt von der Vorhersage der zukünftigen Trajektorie.

Das Ziel und die globale Vision dieser Arbeit (siehe [Bi21]) sind kooperativ-interagierende, hoch-automatisierte Fahrzeuge, die das Verhalten von ungeschützten Verkehrsteilnehmern berücksichtigen können. Die kollektive Intelligenz aller Fahrzeuge, ergänzt durch Informationen von RSU und von den ungeschützten Verkehrsteilnehmern bei sich getragenen Smart Devices, wird ausgenutzt, um die Sicherheit von ungeschützten Verkehrsteilnehmern zu erhöhen, indem deren Absichten prognostiziert werden. Im Folgenden werden alle Fahrzeuge, RSU und mit Smart Devices ausgestatteten ungeschützte Verkehrsteilnehmer als Agenten bezeichnet. Wir gehen nicht davon aus, dass alle Agenten immer mit der identischen Sensorik ausgestattet sind oder dass alle Informationen immer verfügbar sind. Stattdessen wird ein opportunistischer Ansatz angestrebt, d.h. es werden alle verfügbaren Informationen so gut wie möglich genutzt. Die Beiträge dieser Arbeit zu dem skizzierten zukünftigen Verkehrsszenario sind Algorithmen und Techniken zur opportunistischen kooperativen Absichtserkennung von Radfahrern.

2 Radfahrer-Absichtserkennung

Im Rahmen dieser Arbeit bezeichnen die Begriffe „Absicht“ bzw. „Intention“ eine geplante, aber noch nicht gestartete bzw. durchgeführte Aktion. Die Absichtserkennung (oder auch Intentionserkennung) wird als ein zweistufiger Prozess (siehe Abb. 2) (vgl. [Bi17]) betrachtet. Im ersten Schritt wird die Bewegung des Radfahrers als eine Abfolge von Bewegungszuständen, z.B. Warten, Starten, Fahren und Abstoppen, gesehen. Das erste Ziel ist die frühzeitige Erkennung von Bewegungsübergängen, d.h. Änderungen des Bewegungszustands. Im zweiten Schritt wird die Bewegung bestimmter Körperpunkte, z.B. des Körperschwerpunkts, der Gelenke oder des Kopfes, im 3D-Raum berücksichtigt. Ziel ist es die zukünftige Trajektorie dieser Punkte für einen maximalen Zeitraum von 2.5 s vorherzusagen. Der Grund für die zweistufige Modellierung ist, dass das frühzeitige Wissen über eine Bewegungszustandsänderung die Vorhersage der zukünftigen Radfahrertrajektorie erheblich verbessert [Go16]. Sowohl die Erkennung des aktuellen Bewegungszustandes als auch die Trajektorienvorhersage sind Teil dessen, was wir als Absichtserkennung bezeichnen. Für die Detektion des Bewegungszustands sowie auch für die Prädiktion der zukünftigen Trajektorie werden maschinelle Lernverfahren verwendet. Für die Absichtserkennung betrachten wir je nach Agenten unterschiedliche Sensormodalitäten bspw. Videosequenzen einer Kamera oder abstraktere Daten wie die vergangenen Positionen, Ge-

schwindigkeiten, Beschleunigungen, Ausrichtungen und Posen des Radfahrers. Die erkannte Absicht bzw. die prädizierte zukünftige Trajektorie kann anschließend zur Situationsanalyse oder zur sicheren Manöverplanung verwendet werden [ES17].

3 Forschungsfragen und Wesentliche Beiträge

Die wesentlichen Beiträge der Arbeit lassen mittels der folgenden drei zentralen Forschungsfragen zusammenfassen:

Probabilistische Radfahrer-Trajektorienvorhersage – Wie kann die zukünftige Trajektorie eines Radfahrers probabilistisch vorhergesagt werden?

Prognosen über das zukünftige Verhalten von Radfahrern sind von Natur aus mit Unsicherheiten behaftet, da nicht alle Variablen, die das zukünftige Verhalten der Radfahrer beeinflussen, bekannt sind. Ziel der probabilistischen Trajektorienvorhersage ist es die (Un-)Sicherheit der Vorhersage zu modellieren und zu quantifizieren. Die Quantifizierung der Unsicherheit bei der Prognose ist ein wesentlicher Aspekt für sicheres hochautomatisiertes Fahren [Ei17]. Im Rahmen dieser Arbeit wird eine neuartige probabilistische Vorhersagemethode vorgestellt. Dabei wird die Unsicherheit mittels einer Wahrscheinlichkeitsverteilung modelliert. Die in dieser Arbeit neu entwickelte Methode auf Basis von neuronalen Netzwerken sowie der Generalisierung der Quantilen Regression erlaubt eine situationsabhängige, stets zuverlässige und zu gleich genaue Schätzung der zukünftigen Radfahrertrajektorie sowie der mit der Prognose einhergehenden Unsicherheit. Im Rahmen einer umfangreichen Studie wird in der Arbeit gezeigt, dass mit dieser Methode eine Steigerung der Güte der probabilistischen Prognosen von bis zu 99 % im Vergleich zu klassischen maschinellen Lernverfahren erreicht werden kann.

Radfahrer als zusätzliche Sensoren – Wie können Smart Devices für die Radfahrer-Absichtserkennung eingesetzt werden?

Laut einer Umfrage des Branchenverbandes Bitkom gab es 2018 in Deutschland 57 Millionen Smartphone-Nutzer, d.h. acht von zehn Menschen in Deutschland besitzen und nutzen ein Smartphone. Smart Devices, d.h. Smartphones, Smartwatches und anderen Wearables, verfügen über zahlreiche Sensoren darunter GPS, Accelerometer, Gyroskop und Magnetometer. Ziel ist es die Sensoren der Smart Devices für die Radfahrer-Absichtserkennung zu nutzen. Durch die Verfügbarkeit neuer Kommunikationstechnologien (z.B. 5G) wird es zudem möglich sein, dass Smart Devices mit Fahrzeugen oder RSU vernetzt werden können [SvSM17]. Ein Radfahrer ist somit selbst in Lage Information an Fahrzeuge oder RSU über die eigene Position, die aktuelle Bewegung (z.B. wartend oder fahrend) sowie der zukünftigen prädizierten Trajektorie zu schicken. Im Rahmen dieser Arbeit wird ein neuartiges Konzept zur Radfahrer-Absichtserkennung mittels Smart Devices unter Verwendung maschineller Lernmethoden vorgestellt. Darüber hinaus wird das Potential von intelligenten Fahrradhelmen zur Radfahrer-Absichtserkennung dargelegt. Zudem wird gezeigt, dass die Vernetzung mehrerer am Körper getragener smarter Geräte in Form eines neuartigen Fahrrad Ad Hoc Netzwerk (engl. Bicycle Area Network kurz BicAN), zu einer deutlich verbesserten Absichtserkennung führt.

Kooperative Absichtserkennung – *Wie können Absichten von Radfahrern kooperativ erkannt werden?*

Das Ziel dieser Arbeit ist, dass die kollektive Intelligenz aller Verkehrsteilnehmer sowie RSU und Smart Devices genutzt wird, um die Absichten von Radfahrer im Rahmen eines kooperativen Prozesses frühzeitig und vor allem zuverlässig zu erkennen. Die Kooperation beschreibt hier im Wesentlichen einen Fusionsprozess, der auf unterschiedlichen Ebene stattfinden kann, z.B. auf Ebene der Eingabe in den Absichtserkennungsprozesses (Kooperative Wahrnehmung), oder auf Ebene der detektierten Bewegungszustände, oder der prädizierte zukünftigen Trajektorien. Eine Besonderheit ist hierbei die Heterogenität der Sensoren der beteiligten Agenten. Dies reicht von Bildern von Fahrzeug- und Verkehrskameras bis hin zu den Inertialsensoren der Smart Devices. Darüber hinaus sind auch Effekte, wie z.B. Verzögerungen, verlorene oder außerhalb der Sequenz ankommende Nachrichten, welche durch die Verwendung des unterliegenden drahtlosen Kommunikationsmediums (z.B., 5G oder ITS-G5) entstehen können, beim Entwurf der Methoden zur kooperativen Absichtserkennung zu betrachten.

4 Probabilistische Radfahrer-Trajektorienvorhersage

Die probabilistische Trajektorienprognose hat das Ziel die zukünftige Aufenthaltswahrscheinlichkeit des Radfahrers zu modellieren, d.h. anstatt einer Punktprognose wird eine Wahrscheinlichkeitsverteilung über mögliche zukünftige Aufenthaltsorte prädiziert. Die vorhergesagten Verteilungen sollen dabei nicht statisch sein, sondern sich der beobachteten Situation anpassen. Ziel der probabilistischen Vorhersagemethoden ist es immer möglichst scharfe (d.h. kompakte) Verteilungen vorherzusagen. Die Randbedingung ist dabei, dass die vorhergesagten Verteilungen zuverlässig sind, d.h. wenn man aus einer Verteilung den Bereich mit 95 % Aufenthaltswahrscheinlichkeit extrahiert, dann sollte der Radfahrer auch tatsächlich in 95 % der Fälle in diesem Bereich sein. Letzteres wird auch als Zuverlässigkeit der Vorhersage bezeichnet. Insbesondere die Zuverlässigkeit von probabilistischen Prognosen für Radfahrer ist eine große Herausforderung, z.B. bei Übergängen zwischen Bewegungszuständen. Mit sehr großer Wahrscheinlichkeit wird der Radfahrer das was er gerade macht auch in der kommenden Sekunde machen, d.h. wenn der Radfahrer geradeaus fährt, dann ist die Wahrscheinlichkeit, dass er dies auch in der nächsten Sekunden machen wird, sehr hoch. Es besteht trotzdem noch zu einem geringen Anteil die Möglichkeit, dass er plötzlich abbremst oder abstoppt. Die für die Modellierung notwendigen multivariaten Verteilungen sind schief und haben schwere Ränder, weshalb klassische Methoden wie bspw. neuronale Netzwerke mit Gaußscher Likelihood nicht geeignet sind, bzw. keine zuverlässigen Vorhersagen zulassen (siehe [Ze19]). Im Rahmen dieser Arbeit wird eine neuartige Methode zur Modellierung beliebiger, multivariater, unimodaler, sternförmigen Verteilungen vorgestellt. Diese neue Methode ist eine Erweiterung der weit verbreiteten Quantilen Regression (QR) [KB78] auf multivariate Zielgrößen. Der große Vorteil der QR ist die nicht-parametrische Natur der Vorhersagen, d.h. es können beliebige Verteilungen modelliert werden insbesondere auch schiefe und solche mit schweren Rändern. QR-Methoden sind allerdings nur für die Vorhersage univariater (d.h. eindimensionaler) Zielgröße geeignet, da sie auf der Vorhersage von Quantilen beruhen. Da es jedoch bei multivariaten (d.h. mehrdimensionalen) Zielgrößen keine inhärente Ordnung

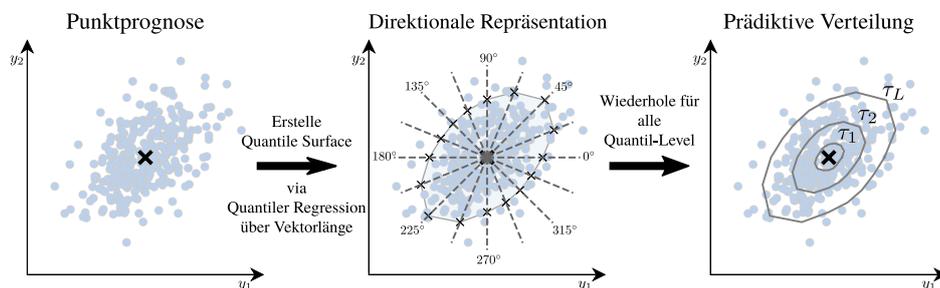


Abb. 3: Illustration der Quantile Surface Vorhersagemethode: Deterministische Punktprognose und Erstellung der Quantile Surfaces mittels direktonaler Repräsentation.

gibt, stellt die Erweiterung von Quantilen und damit der QR Methode auf multivariate Zielgrößen eine große Herausforderung dar.

Die neue Methode, genannt Quantile Surface (QS) Vorhersage, besteht aus zwei Schritten. Im ersten Schritt wird eine deterministische Punktprognose für die zukünftige Trajektorie erstellt. Dieses Netzwerk prognostiziert auf Basis von Eingabemerkmale (hier die vergangene Radfahrertrajektorie) das Lagemaß (z.B. den geometrischen Median) der vorherzusagenden Verteilung. Im zweiten Schritt werden jetzt ausgehend von dieser Punktprognose Ränder von Gebieten (den sogenannten Quantile Surfaces) geschätzt, die einen bestimmten Träger (engl. Support) der Verteilung beinhalten, z.B. 95 % der zu erwartenden Beobachtungen. Eine Beobachtung entspricht hier einer tatsächlich beobachteten Radfahrerposition im Vorhersagezeitraum. Die Kernidee ist die Verwendung einer sogenannten direktonalen Repräsentation der Beobachtungen ausgehend von der deterministischen Punktprognose. Im zweidimensionalen Fall entspricht diese Art der Repräsentation einer Darstellung mittels Polarkoordinaten. Die Quantile Surface für ein bestimmtes Quantile-Level ergibt sich durch die Anwendung der QR Methode über die Vektorlänge des Vektors von der deterministischen Punktprognose zur Beobachtung, d.h. es wird versucht das Ausmaß des Gebietes in eine bestimmte Richtung zu beschreiben. Die komplette prädizierte Verteilung ergibt sich aus der Anwendung dieser Methodik für unterschiedliche Richtungen und diskrete Quantil-Level τ , z.B. 5%, 10% ..., 95%. Das Verfahren ist exemplarisch in Abb.3 dargestellt.

Für die QR wird kein lineares Modell verwendet, sondern ein neuronales Netzwerk mit nicht-linearen Aktivierungsfunktionen. Dieses Netzwerk bekommt als Eingabe die vergangene Trajektorie des Radfahrers sowie die Richtung, für welche das Ausmaß der QS bestimmt werden soll. Die Ausgabe des Netzwerks sind diskrete Quantil-Level für das Ausmaß der QS in die jeweilige Richtung. Die Parameter des Netzwerkes werden mittels der Quantile Fehlerfunktion (auch bekannt als Pinnball Fehlerfunktion) optimiert. Mit Hilfe des QS Verfahrens können zuverlässige und zugleich scharfe Prognosen für die zukünftige Radfahrertrajektorie erstellt werden. Im Rahmen eine Studie mit 107 Radfahrern erreicht die QS-Vorhersagemethode eine 99% Verbesserung bzgl. Güte der probabilistischen Vorhersage (gemessenen mittels des Continuous Ranked Probability Scores) verglichen zu klassischen Methoden.

5 Radfahrer als zusätzliche Sensoren

Heutzutage trägt fast jeder Mensch ein Smartphone oder anderes Wearable Device bei sich. Es gibt zahlreiche Studien, welche die Verwendung von Smart Devices für die Aktivitätserkennung (d.h. die Erkennung der aktuellen Bewegung) von Fußgängern einsetzen (siehe [SvSM17] für eine detaillierte Auflistung). Die Verwendung von Smart Devices für die Absichtserkennung (d.h. auch die Trajektorienvorhersage) von Radfahrern wurde jedoch bisher nur wenig untersucht. Im Rahmen dieser Arbeit wird diese Forschungslücken geschlossen und zahlreiche Aspekte der Smart Device gestützten Radfahrer-Absichtserkennung untersucht, darunter die Smart Device gestützte Bewegungszustandsdetektion und Trajektorienvorhersage sowie insbesondere auch die Untersuchung des Einflusses der Trageposition des Gerätes auf die Erkennungsleistung.

Smart Device gestützte Lokalisierung und Geräte-Trageposition Im Rahmen einer Fallstudie wird gezeigt, dass die Positionierungsgenauigkeit aktueller Smart Devices (d.h. handelsüblicher Android Smartphones) noch nicht ausreichend ist, um eine rein GPS-gestützte Absichtserkennung durchzuführen. Insbesondere bei Geräten, welche an Positionen getragen werden, bei denen das GPS-Signal stark durch den Körper abgeschirmt wird (z.B. der Hosentasche), ist die Positionsgenauigkeit noch nicht ausreichend. Andere Geräte, welche an mehr exponierten Positionen getragen werden, z.B. am Handgelenk oder auf dem Helm, zeigen deutlich bessere Ergebnisse. Zudem wird auch gezeigt, dass die Geräte-Trageposition mittels maschineller Lernverfahren auf Basis der Inertialsensoren zuverlässig klassifiziert werden kann [Bi18]. Diese Information kann zur nachträglichen Bewertung der Lokalisierungsgenauigkeit verwendet werden.

Bewegungszustandsdetektion und Trajektorienvorhersage Ein zentraler Beitrag für die Einbindung von Radfahrern als zusätzlichen Sensoren ist ein neuartiger Prozess zur schnellen und zuverlässigen Bewegungszustandserkennung unter Verwendung der Inertialsensorik (d.h. Accelerometer und Gyroskop). Herzstück dieses Prozesses sind Methoden der menschlichen Aktivitätserkennung (engl. Human Activity Recognition, kurz HAR) in Kombination mit Methoden des maschinellen Lernens [BSS18]. Im Rahmen der Untersuchung mit 107 Radfahrern wird gezeigt, dass die Ergebnisse dieser neuartigen Detektionsmethode vergleichbar sind mit denen eines rein Fahrzeugkamera gestützten Ansatzes. Die Gerät-Trageposition hat auch hier einen starken Einfluss auf die Detektion, so eignet sich bspw. das Smartphone, welches in der Hosentasche getragen wird, besonders gut für die Radfahrer-Anfahrtserkennung. Der Ansatz zur Bewegungszustandserkennung wird durch einige Modifikationen, darunter der Verwendung eines neuronalen Netzwerks, auch für die Trajektorienprädiktion weiterentwickelt. Nach bestem Wissen und Gewissen ist dies das erste Mal, dass der Einsatz von Smart Devices für die Radfahrer-Trajektorienprädiktion untersucht wird. Die Ergebnisse hier sind nicht vergleichbar mit denen eines rein Fahrzeugkamera gestützten Ansatzes, kommen diesem aber in einigen Aspekten (z.B. die Prädikationen von abbiegenden Radfahrern) bereits sehr nahe. Als ein limitierender Faktor stellt sich hierbei insbesondere die Lokalisierungsgenauigkeit der Smart Devices heraus.

Verwendung mehrerer kooperierender Smart Devices und Smartheilm In Zukunft werden die Menschen anstatt eines einzelnen Smartphones eine Vielzahl von smarten End-

geräten mit sich führen. Dies reicht von Smartwatches über mit Sensorik ausgestattete Kleidung bis hin zu intelligenten Fahrrädern sowie intelligente mit Sensorik ausgestatteten Helmen (engl. Smarthehelmet). Im Rahmen dieser Arbeit wird ein neuartiger Ansatz skizziert in dem diese Geräte durch ein Fahrrad Ad Hoc Netzwerk (engl. Bicycle Area Network kurz BicAN) miteinander verbunden sind, Informationen austauschen und kooperieren. Im Rahmen einer umfangreichen Fallstudie mit 51 Radfahrern und drei Smart Devices, d.h. einem Smartphone in der Hosentasche, einer Smartwatch am Handgelenk und einem Smarthehelmet, kann gezeigt werden, dass die Kombination der Informationen aller Geräte zu einer deutlich verbesserten Bewegungszustandsdetektion führt. Darüber hinaus wird das Potenzial eines Smarthehelms im Kontext einer verbesserten Eigenlokalisierung und Orientierungsschätzung für die Radfahrer-Absichtserkennung aufgezeigt.

6 Kooperative Methoden zur Absichtserkennung

Im Rahmen dieser Arbeit stellen werden drei Ansätze zur kooperativen Radfahrer-Absichtserkennung vorgestellt: 1.) Fusion mittels eines kooperativ-erstellten probabilistischen Modells der vergangenen Trajektorie des Radfahrers, 2.) Kooperation zur verbesserten Detektion des aktuellen Bewegungszustands und 3.) Kooperation auf Ebene von vorhergesagten Trajektorien. Um die Ansätze evaluieren zu können, wurde im Rahmen dieser Arbeit in drei großangelegten Messkampagnen Daten von 107 Radfahrern an einer öffentlichen Kreuzung in Aschaffenburg aufgezeichnet. Von jedem dieser Radfahrer liegen Daten sowohl von Verkehrskameras, als auch Daten aus einem Versuchsträger sowie auch von den vom Radfahrer bei sich getragenen Smart Devices vor. Die Evaluation der unterschiedlichen Verfahren findet offline mit den erhobenen Daten statt. Ein weiterer wesentlicher Beitrag dieser Arbeit ist die Bewertung der unterschiedlichen Verfahren hinsichtlich ihrer Umsetzbarkeit mit den im aktuellen ETSI Standard definierten Nachrichtentypen.

Probabilistische Trajektorienfusion mittels Orthogonaler Polynome Die zugrundeliegende Idee dieses kooperativen Ansatzes ist, dass alle Agenten die aktuelle Position der beobachteten Radfahrer teilen. Die vergangene Trajektorie eines Radfahrers bzw. die Messungen der Positionen aller Agenten über dessen Position wird durch ein Polynom mit orthogonalen Basisfunktionen approximiert. Die Fusion wird somit durch die Approximation der Positionsmessungen mittels eines Polynoms realisiert. Die Koeffizienten des orthogonalen Basispolynoms des approximierenden Polynoms werden als Merkmale für die Absichtserkennung verwendet (siehe [Go16]). Die Stärke des Ansatzes im Vergleich zu klassischen Verfahren wie Kalman Filtern ist, dass dieser Ansatz ohne Modifikationen mit zeitlich verzögerten Messungen sowie außerhalb der Sequenz ankommende Messungen umgehen kann. Auf Grund der methodischen Nähe zu kooperativen Tracking-Verfahren ist dieses Verfahren mit den Nachrichtentypen, welche im ETSI Standard definiert sind, bereits heute umsetzbar.

Kooperative Bewegungszustandsdetektion Das Ziel der kooperativen Bewegungszustandsdetektion ist es durch die Fusion der Informationen und Messungen von mehreren Agenten die Bewegungszustandsdetektion zu verbessern. Hierfür werden unterschiedliche Methoden untersucht, u.a. die Konkatenation des Eingaberaums mehrere Agenten, ein

Bayesscher Ansatz zur Fusion von Entscheidungen und Methoden des maschinellen Lernens (z.B. das Anlernen von Ensembles). Kooperation auf Ebene der Detektion der Bewegungszustände stellt sich als äußerst vielversprechend heraus, so kann durch die Fusion die Robustheit der Bewegungszustandsdetektion um bis zu 43% im Vergleich zu einem nicht-kooperativen Ansatz gesteigert werden. Zudem werden auch Übergänge zwischen Bewegungszuständen deutlich schneller erkannt. Da für die Kooperation auf Basis der Bewegungszustandsdetektion keine exakte Positionierungsinformation notwendig ist, stellt diese Art der Kooperation eine hervorragende Möglichkeit dar, um Smart Devices zu integrieren. Für die praktische Umsetzung der kooperativen Bewegungszustandsdetektion sind lediglich kleinere Erweiterungen des ETSI Standards notwendig.

Kooperative Trajektorienvorhersage Bei diesem Ansatz handelt es um die Fusion auf Ebene der Trajektorienvorhersagen, d.h. die Agenten tauschen Vorhersagen aus. Zur Fusion wird ein neuartiger Ansatz auf Basis des Cooperative Soft Gating Ensembles (kurz CSGE) [De18] entwickelt und untersucht. Die Vorhersage von unterschiedlichen Agenten werden auf Basis von drei Komponenten (einer globalen, einer situationsabhängigen und einer temporalen Komponente) bewertet. Auf Basis dieser Bewertung wird eine Gewichtung für die Fusion der Vorhersage der Agenten ermittelt. Das CSGE ist um die Fähigkeit erweitert worden zeitliche verzögerte Vorhersage (z.B. auf Grund eines Kommunikation Verzögerungen) mit zu berücksichtigen. Die kooperative Trajektorienvorhersage mittels des CSGE erweist hinsichtlich des Vorhersagefehlers als der beste Ansatz. Für dieses Verfahren kann sogar gezeigt werden, dass im Vergleich zu einem nicht-kooperativen Ansatz ein statistisch signifikanter besserer durchschnittlicher Rang (bzgl. des Vorhersagefehlers) erzielt wird. Für die praktische Umsetzung des Verfahrens im realen Verkehr sind deutliche umfangreichere Erweiterungen des ETSI Standards nötig.

7 Zusammenfassung und Fazit

In dieser Arbeit wird ein opportunistischer Ansatz zur kooperativen Absichtserkennung von Radfahrern vorgestellt [Bi21]. Dabei werden unterschiedliche neue Aspekte betrachtet, darunter eine neuartige probabilistische Vorhersagemethode, unterschiedlichste Verfahren für die Verwendung von Radfahrern als zusätzliche Sensoren und zu guter letzte zahlreiche Verfahren für die kooperative Absichtserkennung auf diversen Ebenen. Die Ergebnisse dieser Untersuchungen sind vielversprechend und haben das Potential in Zukunft das Radfahren sicherer zu machen. Die nächsten Schritte für zukünftige Forschung sind größere Messkampagnen und Versuchsreihen in denen die Realisierung der Verfahren im online Betrieb mit mehreren Fahrzeugen, RSU und Radfahrern mit Smart Devices untersucht wird.

Literaturverzeichnis

- [Bi17] Bieshaar, M.; Reitberger, G.; Zernetsch, S.; Sick, B.; Fuchs, E.; Doll, K.: Detecting Intentions of Vulnerable Road Users Based on Collective Intelligence. In: AAET - Automatisiertes und vernetztes Fahren. Braunschweig, Germany, S. 67–87, 2017.

- [Bi18] Bieshaar, M.: Organic Computing: Doctoral Dissertation Colloquium. Kapitel Where is my Device? - Detecting the Smart Device's Wearing Location in the Context of Active Safety for Vulnerable Road Users, S. 27–37. Kassel University Press, 2018.
- [Bi21] Bieshaar, M.: Cooperative Intention Detection using Machine Learning–Advanced Cyclist Protection in the Context of Automated Driving. Intelligent Embedded Systems. Kassel University Press, 2021. (Dissertation, Universität Kassel, Fachbereich Elektrotechnik/Informatik).
- [BSS18] Bieshaar, M. and Depping, M.; Schneegans, J.; Sick, B.: Starting Movement Detection of Cyclists using Smart Devices. In: International Conference on Data Science and Advanced Analytics (DSAA). Turin, Italy, S. 313–322, 2018.
- [De18] Deist, S.; Bieshaar, M.; Schreiber, J.; Gensler, A.; Sick, B.: Cooperative Soft Gating Ensemble. In: Workshop on Self-Improving System Integration (SISSY). Trento, Italy, 2018.
- [Ei17] Eilbrecht, J.; Bieshaar, M.; Zernetsch, S.; Doll, K.; Sick, B.; Stursberg, O.: Model-predictive planning for autonomous vehicles anticipating intentions of vulnerable road users by artificial neural networks. In: Symposium Series on Computational Intelligence (SSCI). Honolulu, HI, S. 2869–2876, 2017.
- [ES17] Eilbrecht, J.; Stursberg, O.: Cooperative driving using a hierarchy of mixed-integer programming and tracking control. In: Intelligent Vehicles Symposium (IV). Los Angeles, CA, S. 673–678, 2017.
- [Go16] Goldhammer, M.: Selbstlernende Algorithmen zur videobasierten Absichtserkennung von Fußgängern. Intelligent Embedded Systems. Kassel University Press, 2016. (Dissertation, Universität Kassel, Fachbereich Elektrotechnik/Informatik).
- [KB78] Koenker, R.; Bassett, G.: Regression Quantiles. *Econometrica*, 46:33–50, 1978.
- [SvSM17] Scholliers, J.; van Sambeek, M.; Moerman, K.: Integration of vulnerable road users in cooperative ITS systems. *European Transport Research Review (ETRR)*, 9(2):15, 2017.
- [Wo18] World Health Organization: Global Status Report on Road Safety 2018. World Health Organization, Geneva, Switzerland, 2018.
- [Ze19] Zernetsch, S.; Reichert, H.; Kress, V.; Doll, K.; Sick, B.: Trajectory Forecasts with Uncertainties of Vulnerable Road Users by Means of Neural Networks. In: Intelligent Vehicles Symposium (IV). Paris, France, S. 810–815, 2019.



Maarten Bieshaar wurde am 8. Mai 1990 in Fritzlar, Hessen geboren. Er schloss 2013 den B.Sc. und 2015 den M.Sc. in Informatik an der Universität Paderborn ab. Ab 2016 arbeitet er als wissenschaftlicher Mitarbeiter am Fachgebiet Intelligente Eingebettete Systeme (IES) unter der Leitung von Bernhard Sick an der Universität Kassel. Dort begann er ebenfalls im Jahr 2016 mit seiner Promotion in Informatik, welche er in 2020 mit Auszeichnung abschloss. Seit 2020 leitet er am Fachgebiet IES die Gruppe „AI for Motion“, welche sich mit KI-Themen im Automobilumfeld beschäftigt.