

# Schlussbericht des Karlsruher Instituts für Technologie (KIT) für das BMBF-Forschungsvorhaben



## Personalisierte, adaptive, kooperative Systeme für automatisierte Fahrzeuge

Förderkennzeichen: 16SV7675K  
Projektlaufzeit: 01.01.2017-31.12.2019  
Verfasser: Dr.-Ing. Michael Flad  
Julian Ludwig  
Alina Roitberg  
Philipp Karg  
Prof. Dr.-Ing. Rainer Stiefelhagen  
Prof. Dr.-Ing. Sören Hohmann

Die Verantwortung für den Inhalt des Berichts liegt bei den Autoren.

GEFÖRDERT VOM



Bundesministerium  
für Bildung  
und Forschung

## Inhaltsverzeichnis

1.	Kurzdarstellung zum Projekt PAKoS .....	3
1.1.	Aufgabenstellung.....	4
1.2.	Voraussetzungen, unter denen das Vorhaben durchgeführt wurde .....	6
1.3.	Planung und Ablauf des Vorhabens .....	8
1.4.	Wissenschaftlicher und technischer Stand, an den angeknüpft wurde.....	9
1.4.1.	Fahrerbeobachtung.....	9
1.4.2.	Transition der Fahraufgabe .....	10
1.5.	Zusammenarbeit mit anderen Stellen.....	12
2.	Eingehende Darstellung .....	13
2.1.	Verwendung der Zuwendung und erzielte Ergebnisse .....	13
2.1.1.	Visuelle Fahrererkennung .....	13
2.1.2.	Kooperative Transition der Fahraufgabe.....	26
2.2.	Wichtigste Positionen des zahlenmäßigen Nachweises.....	44
2.3.	Notwendigkeit und Angemessenheit der geleisteten Arbeit.....	44
2.4.	Nutzen und Verwertbarkeit der Ergebnisse im Sinne des fortgeschriebenen Verwertungsplans .....	45
2.4.1.	Wissenschaftliche Erfolge.....	45
2.4.2.	Wirtschaftliche Erfolge .....	46
2.4.3.	Wissenschaftliche und wirtschaftliche Anschlussfähigkeit .....	46
2.5.	Fortschritte auf dem Gebiet des Vorhabens bei anderen Stellen.....	47
2.6.	Erfolgte oder geplante Veröffentlichungen der Ergebnisse.....	48
3.	Literatur .....	50

## 1. Kurzdarstellung zum Projekt PAKoS

Automatisierte Fahrzeuge werden den Fahrer zukünftig nicht nur entlasten, sondern streckenweise sogar ganz von der Fahrverantwortung befreien. Dadurch entstehen vielschichtige, neue Schnittstellen zwischen Fahrer und Fahrzeug. Beispielsweise ist beim automatisierten Fahren auf der Autobahn vorgesehen, die Kontrolle an den Fahrer zurückzugeben, wenn die Autobahn verlassen werden soll. Eine andere Systemgrenze liegt beim Wechseln auf eine andere Autobahn vor oder bei einer unkonventionellen Spurführung in einer Dauerbaustelle. Ebenso zwingend notwendig ist eine Übergabe der Fahrzeugkontrolle bei einer Degradation des Automatisierungslevels, etwa durch den Ausfall eines Sensors. Im Unterschied zu heutigen Assistenzsystemen, die den Fahrer durchweg als aufmerksam, überwachend und stets in der Verantwortung voraussetzen, soll der „Fahrer“, der nun als Nutzer auftritt, bei hochautomatisierten Funktionen im Extremfall völlig unaufmerksam sein dürfen. Bei Pendlern, die auf der Autobahn täglich in dieselbe Baustellensituation geraten, ist in den genannten Szenarien auch in diesem Fall eine schnelle und sichere Übernahme des Steuers zu erwarten. Für den Fahrer eines Kleinbusses, der einen Ausflug mit der Großfamilie und einem für ihn ungewohnten Mietwagen in einer fremden Gegend unternimmt, gilt dies aber nicht. Folglich sind Fahrfunktionen mit höheren Automatisierungsgraden darauf angewiesen, individualisiert und abhängig vom Nutzerzustand zu agieren. Dazu sollten sie das Leistungsvermögen des jeweiligen Fahrers kennen und sich automatisch darauf anpassen können. Gleichzeitig müssen diese Systeme mit dem Menschen kooperieren. Nur so lassen sich die genannten komplexen Szenarien der Kontrollübergabe sicher und komfortabel lösen.

Eine zusätzliche Herausforderung ergibt sich durch die weltweite Zunahme von Carsharing-Angeboten, die das Mobilitätsverhalten künftig bestimmen werden. Entsprechend erweitert sich die Zielgruppe innovativer Mobilitätskonzepte ständig, sodass Fahranfänger, Senioren und Vielfahrer vermehrt dasselbe Auto nutzen. Während personalisierte und individuelle Komforteinstellungen, beispielsweise die bevorzugte Sitz- oder Rückspiegelkonfiguration oder der geliebte Radiosender, bei einem Fahrzeugwechsel leicht manuell übernommen werden könnten, ist eine manuelle Adaption von komplexen Kontrollübergabeparametern nicht möglich und aus der Perspektive der Fahrsicherheit auch nicht zu befürworten. Innovative Lösungen sowohl in der Gestaltung der Mensch-Maschine-Kooperation als auch in der Personalisierung sind also gefragt.

Im Rahmen des Teilvorhabens „PAKoS – Handlungserkennung und kooperative Regelungskonzepte für die adaptive personalisierte Kontrolle“ wurden diesbezüglich zwei Schwerpunkte gesetzt. Zum einen die Identifikation des Fahrers und dessen Handlungen und zum anderen die darauf basierenden Regelungskonzepte zur kooperativen Kontrolle des Fahrzeugs und im Besonderen deren Transition.

## 1.1. Aufgabenstellung

Im Verbund der PAKoS-Projektpartner beschäftigte sich das KIT mit den zwei zentralen Fragestellungen der Fahrerbeobachtung und der Kontrollübergabe zwischen Fahrzeugautomation und menschlichem Fahrer. In diesem Zusammenhang hat die Fahrerbeobachtung zum Ziel, den Fahrer und dessen aktuellen Handlungen zu identifizieren. Diese Informationen bilden die Grundlage für die Personalisierung und Individualisierung der hochautomatisierten Fahrfunktion, welche durch andere Projektpartner realisiert wurde, sowie der Kontrollübergabe. Die Arbeiten zur Fahrerbeobachtung erfolgten dabei im Wesentlichen durch das Computer Vision for Human-Computer Interaction Lab (CVHCI). Den zweiten Schwerpunkt des KIT, die Entwicklung eines Regelungskonzeptes für die kooperative Kontrolle des Fahrzeuges zur Übergabe der Fahraufgabe zwischen Automation und Fahrer, bearbeitete das Institut für Regelungs- und Steuerungssysteme (IRS). Nachfolgend werden die beiden Fragestellungen detailliert dargestellt.

Damit hochautomatisierte Fahrfunktionen sich optimal an den Nutzer anpassen können und um die Interaktionsbereitschaft des Fahrers in einer Kontrollübergabe vorhersagen zu können, ist es erforderlich, die Situation im Innenraum des Fahrzeuges zu erfassen. Merkmale, wie die Identität, Körperhaltung, Blickrichtung sowie die aktuelle Aktivität des Fahrers, lassen sich mittels Algorithmen des Machine Learning, wie tiefe neuronale Netze, automatisch erkennen. Solch eine Einschätzung des Fahrerzustandes ist entscheidend für die Zusammenarbeit zwischen Mensch und Fahrzeugautomation, da sie direkt Rückschlüsse über die Aufmerksamkeit des Fahrers liefert. Neben der Identifizierung der Fahrerablenkung aus Sicherheitsgründen kann die Aktivitätserkennung auch den Komfort erhöhen, z. B. durch Anpassung der Fahrweise beim Trinken oder durch das Einschalten der Beleuchtung im Innenraum beim Lesen eines Buchs. Das Ziel des CVHCI war somit die *Deep-Learning-basierte Erkennung von Fahrernebenaktivität unter realen Einsatzbedingungen* (z. B. unter Berücksichtigung der Unsicherheit durch neue Aktivitäten und mit Verwendung anwendungsspezifischer Sensorik). Dabei sollten sowohl komplexe Verhaltensweisen als auch einfache Interaktionen mit der Umgebung (Handlungsatome) erkannt werden. Da tiefe neuronale Netze eine große Menge an Trainingsdaten benötigen, war ein erstes wichtiges Ziel die Sammlung eines annotierten Datensatzes mit Aufnahmen von Fahrernebenaktivitäten während der hochautomatisierten Fahrt. Hierfür sollten zunächst relevante, zu betrachtende Handlungen und Situationen im Fahrzeuginnenraum identifiziert werden und auf deren Basis anschließend der Versuchsablauf der Studien zur Datengenerierung abgeleitet werden. Bei der Sammlung und Annotation dieses Datensatzes war eine Schnittstelle und Kooperation mit einem weiteren Projektpartner, dem Fraunhofer IOSB, vorgesehen. Infolgedessen hat sich das CVHCI neben der

Konzeption gemeinsam mit dem Konsortialpartner an der Probandensuche, Durchführung der Datenaufzeichnung und Annotation der Daten beteiligt. Dies schließt die Bereitstellung eines passenden Annotationschemas ein. Dabei ist zu berücksichtigen, dass die Annotation eine hierarchische Struktur aufweisen musste, um sowohl die Erkennung zusammengesetzter Verhaltensweisen, als auch der Handlungsatome zu ermöglichen.

Das zweite große Ziel des CVHCI war schließlich die Umsetzung der Deep-Learning-Algorithmen. Dafür sollten mehrere Architekturen aus dem Stand der Forschung für die Aktivitätserkennung im Fahrzeug angepasst und verbessert werden (sowohl für die Nebentätigkeiten, als auch die Handlungsatome). Insbesondere sollte auf anwendungsrelevante Themen geachtet werden, wie z. B. die Einschätzung der Unsicherheiten von Deep Learning, da der Datensatz nicht alle möglichen Aktivitäten abdecken kann und neue Verhaltensweisen stets aufkommen können. Darüber hinaus sollten Verfahren zur Sensorfusion untersucht und weiterentwickelt werden, da unterschiedliche Sensoren individuelle Vor- und Nachteile im Fahrzeuginnenraum besitzen. Zudem sollten, nach Bedarf anderer Projektpartner, weitere Merkmale, wie z. B. die Kopfpose, erkannt werden. Die entwickelten Verfahren galt es letztlich hinsichtlich ihrer Erkennungsgenauigkeit zu evaluieren und in die Demonstrationssysteme (Simulator und Testfahrzeug) zu integrieren.

Automatisierte Fahrzeuge werden den Fahrer zukünftig nicht nur entlasten, sondern streckenweise sogar ganz von der Fahrverantwortung befreien. Allerdings muss die Fahraufgabe an den Systemgrenzen wieder an den Fahrer übergeben werden. Beispiele für derartige Grenzen des Betriebsbereichs der hochautomatisierten Fahrfunktion sind das Verlassen oder der Wechsel der Autobahn, aber auch die unkonventionelle Spurführung in einer Dauerbaustelle. Neben diesen geplanten Systemgrenzen ist eine Kontrollübergabe auch im Falle einer Degradation des Automatisierungslevels nötig, d. h. der Fahrer steht als Rückfallebene zur Verfügung, beispielsweise beim Ausfall eines Sensors für die Umfelderkennung. Da der Fahrer während der hochautomatisierten Fahrt Nebentätigkeiten nachgehen kann, wird ein geeignetes Konzept benötigt, sodass die Übergabe der Fahrzeugkontrolle von Automation zum menschlichen Fahrer hinreichend schnell, jedoch ohne Gefährdung der Fahrzeugsicherheit erfolgt. Ziel des IRS war die *regelungstechnische Umsetzung dieser Übergabephase*. Hierfür sollte eine kooperative Transitionsphase entwickelt und realisiert werden, in der Fahrer und Automation die Fahraufgabe gemeinsam absolvieren. Infolgedessen wird der Fahrer langsam an die neue Aufgabe herangeführt, entsprechend seiner mentalen Leistungsbereitschaft das Fahrzeug zu führen. Für die Realisierung des Konzepts musste die Kooperation zwischen Nutzer und Fahrerassistenzsystem während dieses Übergabeprozesses zunächst systemtheoretisch modelliert werden. Dies schließt Beschreibungen der Kommunikation, der Interaktion und der individuellen Absichten der beiden Partner mit ein. Auf Basis des Modells lassen sich anschließend

Regelungskonzepte entwerfen, welche die Transition entweder so gestalten, dass der Mensch die Aufgabe sicher übernehmen kann oder sich selbst in der Art adaptieren, dass sie einen durch den Menschen vorgegebenen Transitionsverlauf passend ergänzen. Damit eine Anwendung im realen Fahrzeug erfolgen kann, werden performante und robuste Regelalgorithmen benötigt. Die Validierung der vom IRS entwickelten Funktionen erfolgte mit Hilfe von Fahrsimulatorstudien, die in Kooperation mit dem Lehrstuhl für Ergonomie an der Technischen Universität München, einem weiteren Projektpartner des PAKoS-Verbundes, durchgeführt wurden.

## 1.2. Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

Im Rahmen des Projekts wurden drei Nutzergruppen identifiziert, die sich hinsichtlich ihrer Akzeptanz und Nutzung hochautomatisierter Fahrfunktionen unterscheiden: „Wenig-Fahrer“, „Normal-Fahrer“ und „Viel-Fahrer“. Eine Berücksichtigung der individuellen Charakteristika dieser Nutzergruppen stellt somit eine besondere Herausforderung für die zukünftige hochautomatisierte Mobilität dar. Während sich „Wenig-Fahrer“ dadurch auszeichnen, dass sie häufig auf das Angebot von Carsharing-Diensten oder Leihwagen zurückgreifen, sind „Viel-Fahrer“ im Rahmen ihrer Tätigkeit häufig in unterschiedlichen Fahrzeugen unterwegs. Bei „Normal-Fahrern“ entstehen Fahrerwechsel v. a. dadurch, dass deren Fahrzeuge von mehreren unterschiedlichen Nutzern gefahren werden (z. B. mehreren Personen in einem Haushalt). Die Anforderungen, die diese Nutzergruppen an (hoch)automatisierte Fahrzeuge stellen, sind folglich unterschiedlich. Während „Normal-Fahrer“ die Mensch-Maschine-Schnittstelle „ihres“ Fahrzeugs mit der Zeit erlernen, ist dies für Nutzer von Carsharing-Angeboten aufgrund wechselnder Fahrzeugtypen erheblich aufwändiger. Als Konsequenz ergibt sich, dass „Wenig-Fahrer“ viele vorteilhafte Funktionen eines Fahrzeuges nicht oder nur sehr eingeschränkt nutzen. Komplexere Systeme, wie etwa Fahrerassistenzsysteme, werden dabei schon heute häufig gemieden. Dies geht sogar so weit, dass Carsharing-Unternehmen bestimmte Fahrzeugfunktionen durch den Fahrzeughersteller abschalten lassen.

Grundsätzlich sind in allen Nutzergruppen Szenarien, die je nach Nutzergruppe ggf. unterschiedlich häufig auftreten, denkbar, in denen **wechselnde Nutzer eines oder verschiedener Fahrzeuge** involviert sind. Zudem ist im Kontext hochautomatisierter Fahrfunktionen in allen Gruppen stets eine geeignete **Kooperation zwischen Fahrzeug und Fahrer erforderlich**, nicht zuletzt bei der Kontrollübergabe an den Systemgrenzen. Dies macht ein Konzept zur Individualisierung und Personalisierung eminent wichtig für die Akzeptanz hochautomatisierter Fahrfunktionen in diesen Fahrergruppen.

Szenarien mit **wechselnden Nutzern** oder einer **Kooperation zwischen Fahrzeug und Fahrer** sind in der Anwendung vielfältig. Im Projekt wurden folgende Gruppen von Szenarien gebildet:

- **Fahrkooperative Anwendungsszenarien** sind dadurch gekennzeichnet, dass es eine enge Wechselwirkung zwischen Fahrer und Fahrzeug gibt. Ein Beispiel ist die Transition (Übergabe bzw. Übernahme) der Fahraufgabe bei automatisierten Fahrzeugen (initiiert sowohl durch den Fahrer, als auch das Fahrzeug).
- Anwendungsszenarien, die durch eine **weitreichende Individualisierung der Fahrzeugkonfiguration** in einem neuen Fahrzeug charakterisiert werden können. Wesensmerkmal ist eine individualisierte Einstellung von Komfort- und Sicherheitsfunktionen und eine enge Kopplung von Fahrer und Fahrzeug.
- Anwendungsszenarien, die durch eine **portable Personalisierung** gekennzeichnet sind, bei der der Fahrer seine persönlichen Einstellungen in verschiedene Fahrzeuge mitnehmen kann. In diesem Anwendungsfall reichen die Beispiele wiederum von Infotainmentfunktionen über Komfort- und Assistenzfunktionen bis hin zu Sicherheitsfunktionen.

Im Rahmen des Gesamtprojektes wurden alle Felder betrachtet. Die Arbeit des KIT fokussierte sich dabei aber, wie in der Aufgabenstellung bereits konkretisiert, auf zwei Richtungen:

- Die **Transition der Fahraufgabe** in fahrkooperativen Anwendungsszenarien, welche im Fahrsimulator untersucht wurden.
- Die **Innenraumüberwachung und -interpretation** als Basis für die Adaption von Fahrerassistenzsystemen und als eine Basis der **Personalisierung und Individualisierung**.

Beide Fragestellungen sind hinsichtlich der Markteinführung hochautomatisierter Fahrfunktionen sowohl hochgradig relevant, als auch höchst herausfordernd. Während einfache Lösungen für die Fahrererkennung, wie eine Abschätzung der Müdigkeit auf Basis einfacher Heuristiken, bereits heute für den Endkunden verfügbar sind, fehlt eine durchgängige Lösung für die tiefere Interpretation der Innenraumsituation. Auch fehlt bisher vollständig ein Konzept für eine auf den Menschen zentrierte Transition der Fahraufgabe. Die Lösung beider Problemstellungen ist jedoch essentiell für die Implementierung zukünftiger hochautomatisierter Fahrzeuge ab SAE Level 3<sup>1</sup>. Dies wurde zwar bereits von der Industrie erkannt, jedoch liegt deren Fokus aktuell noch auf der marktreifen Umsetzung anderer Funktionalitäten des hochautomatisierten Fahrens, wie beispielsweise der Umfelderkennung oder der Planung kollisionsfreier Trajektorien.

---

<sup>1</sup> Der Automatisierungsgrad der Fahraufgabe kann gemäß der Definition der Society of Automotive Engineers (SAE) in Stufen von 0 bis 5 eingeteilt werden. Level 0 entspricht keiner aktiven Automation, d. h. der Fahrer hat die alleinige Kontrolle über das Fahrzeug, wohingegen bei einem SAE Level 5 Fahrzeug die Automation in allen Szenarien das Fahrzeug führt und keinerlei Überwachung durch den Fahrer notwendig ist. Bei einem Fahrzeug mit SAE Level 3 übernimmt in definierten Bereichen, z. B. Autobahn, die Automation die vollständige Kontrolle ohne eine Überwachung durch den Fahrer, der die Fahraufgabe an den Systemgrenzen wieder übernimmt [SAE.2014].

### 1.3. Planung und Ablauf des Vorhabens

Die Strukturierung der Aufgabenstellung des Gesamtprojekts PAKoS ist in Abb. 1 veranschaulicht. Als Kern des Lösungskonzepts wurden die fünf Bestandteile Innenraumerfassung (AP3), Personalisierung & Nutzerprofil (AP4), Adaption (AP5), Interaktion (AP6) und Persistenz (AP7a) identifiziert, welche durch ihr enges Zusammenspiel die Qualität der Kooperation zwischen

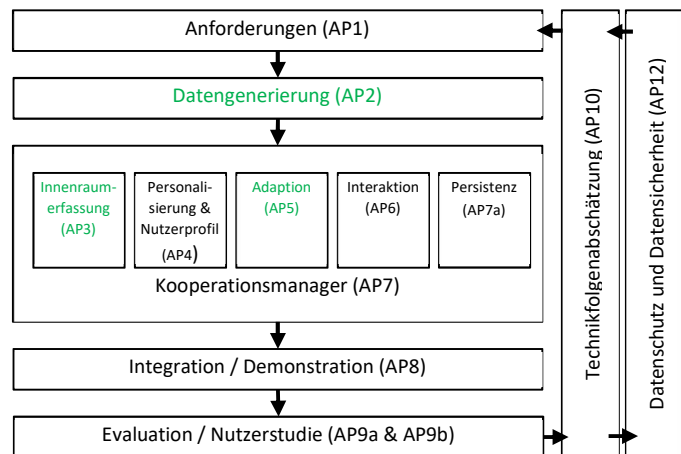


Abbildung 1: Struktur des Projekts PAKoS.

Nutzer und Fahrzeug bestimmen. Das KIT übernahm die Konsortialführung des Verbunds. Inhaltlich bearbeitete das KIT schwerpunktmäßig das AP5 Adaption (Transition der Fahraufgabe) und das AP3 Innenraumerfassung (Erkennung des Nutzerzustands). Hierzu waren auch grundlegende Arbeiten in der Datengenerierung (AP2) notwendig. Die entsprechenden APs sind in Abb. 1 grün hervorgehoben. Für die Organisation wurden insgesamt 55 projektübergreifende Telefonkonferenzen und 11 projektübergreifende Workshops abgehalten. Weitere Telefonkonferenzen und Workshops innerhalb der einzelnen APs wurden zwischen den jeweils betroffenen Partnern durchgeführt.

Der PAKoS-Arbeitsplan leitet sich direkt aus den Zielen ab. Gemäß der Übersicht in Abb. 2 wurden zwei Integrationsstufen geplant. Das Projekt wurde im Wesentlichen wie geplant durchgeführt. Da der für die Datenaufzeichnung zuständige Projektpartner sich aus dem Verbund zurückzog, verzögerte sich das AP3 Innenraumerfassung. In Zusammenarbeit mit dem Fraunhofer IOSB musste ein alternativer Datensatz erstellt werden. Auch konnte, da sich zwischenzeitlich die gesetzlichen Grundlagen geändert hatten und der für den Versuchsträger zuständige Partner neue Anforderungen für den Feldtest einführte, das Transitionskonzept nicht mehr in der Realfahrt getestet werden. Am Ende des Projekts wurden daher als Alternative umfangreiche Studien im Fahrsimulator zu dieser Fragestellung durchgeführt. Darüber hinaus übernahm das KIT als Konsortialführer die Koordination der Fahrversuchsstudien, die nun auf einem Testgelände stattfanden. Diese Anpassungen haben sich aber weder auf die Ergebnisse, noch auf den Gesamtzeitplan des Forschungsprojekts ausgewirkt. Im Gegenteil, es wurde möglich, einen deutlich umfangreicheren Datensatz für die Interpretation von Innenraumsituationen zu erstellen, welcher öffentlich für andere interessierte Anwender und Forscher zugänglich ist. Des Weiteren haben die Fahrsimulatorstudien an Umfang gewonnen und deren Resultate sind reproduzier- sowie belastbarer als die ursprünglich geplante Realfahrt.



AP	Titel	Integrationsstufe 1						Integrationsstufe 2					
		2017				2018		2019					
		Q1	Q2	Q3	Q4	Q1	Q2	Q3	Q4	Q1	Q2	Q3	Q4
1	Anforderungsdefinition												
2	Datengenerierung												
3	Innenraumerfassung												
4	Personalisierung und Nutzerprofil												
5	Adaption												
6	Interaktionskonzeptgestaltung												
7	Kooperationsmanager												
7a	Nutzerschnittstellen												
8	Fahrzeugintegration												
9	Nutzerstudie (a) und Evaluation im Realversuch (b)												
10	Technikfolgenabschätzung												
11	Projektmanagement												
12	Datenschutz und Datensicherheit												

Abbildung 2: Übersicht über den zeitlichen Ablauf des Projekts PAKoS.

#### 1.4. Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

In Übereinstimmung mit der Erläuterung der Aufgabenstellung wird der Stand der Technik in die beiden Fragestellungen Fahrerbeobachtung und Kontrollübergabe bzw. Transition gegliedert.

##### 1.4.1. Fahrerbeobachtung

Bisher hat sich der durch Deep Learning ausgelöste außerordentlicher Fortschritt der videobasierten Aktivitätserkennung eher langsam auf den Bereich der Fahrerbeobachtung ausgewirkt. Da derartige Deep-Learning-Verfahren stark datengetrieben sind, ist dies zu großen Teilen auf den Mangel an großen Fahrerbeobachtungsdatensätzen zurückzuführen. Bestehende Algorithmen für die Erkennung im Fahrzeuginnenraum konzentrieren sich bisher auf eine sehr kleine Menge von möglichen Nebentätigkeiten [Ohn-Bar.2015; Yan.2016]. In [Yan.2016] werden beispielsweise nur drei Zustände, Betätigung des Schalthebels, Essen/Rauchen (zusammengefügt) und Telefonieren, unterschieden und erkannt. Die Evaluation der vorgeschlagenen Methode, die eine Genauigkeit von 99,78% erreicht, gibt jedoch vermutlich ein zu idealistisches Bild ab, da die drei Aktivitätsklassen sehr leicht zu unterscheiden sind. Auch [Ohn-Bar.2015] evaluieren ihre Methode nur für drei Verhaltensweisen, die jeweils mit einer Region des Innenraums verknüpft sind: Aktivitäten in der Lenkrad-Region, der Schalthebel-

Region und der Kombi-Region. Die zunehmende Automatisierung führt dazu, dass sowohl die Häufigkeit, als auch die Komplexität und Vielfalt ablenkender Nebentätigkeiten stark ansteigt. Dadurch reicht eine Klassifizierung in wenige grobe Aktivitäten nicht mehr aus und der Bedarf nach feingranularer Erkennung von einer hohen Menge an möglichen Nebentätigkeiten steigt stark an. Darüber hinaus gab es bisher noch keine Arbeiten, welche die Fahrer Nebentätigkeiten im Kontext des automatisierten Fahrens betrachten. Die feingranulare Erkennung von Fahrer Nebentätigkeiten im Kontext der automatisierten Fahrt stellt somit ein zentrales Ziel von PAKoS dar.

Hinsichtlich der Algorithmen zur Aktivitätserkennung lassen sich die Ansätze in zwei Gruppen unterteilen: (1) Methoden, die auf manuell entworfenen Merkmalen basieren, und (2) End-to-End-Ansätze auf der Basis von Convolutional Neural Networks (CNNs), die direkt auf den Videodaten agieren. Bei den merkmalsbasierten Ansätzen werden die Merkmale häufig aus der Körperhaltung [Ohn-Bar.2014], dem Blick [Ohn-Bar.2014], der Kopfhaltung [Jain.2015] oder der Fahrzeugdynamik [Lefevre.2015] berechnet. Der so generierte Merkmalsvektor wird anschließend mittels eines Verfahrens des maschinellen Lernens verarbeitet. Support Vector Machines, Hidden Markov Models [Jain.2015] oder rekurrente neuronale Netze [Jain.2016] lassen sich als Beispiele nennen. End-to-End-Methoden arbeiten direkt auf den rohen Videodaten, sodass die Zwischendarstellung nicht definiert, sondern durch Faltungsfiler *gelernt* wird. Solche Ansätze basieren häufig auf 3D-CNNs [Tran.2015] zur Erfassung raumzeitlicher Strukturen und erfordern eine große Menge an Trainingsdaten, die bis zu dem im Rahmen von PAKoS entwickelten Drive&Act-Datensatz [Martin.2019b] noch nicht verfügbar waren.

#### 1.4.2. Transition der Fahraufgabe

Fahrerassistenzsysteme beinhalten schon heute Funktionen zur Kontrollübergabe zwischen Fahrer und Fahrzeug [Winner.2009]. Sie lassen sich in Übergabefunktionen klassifizieren, die die von der Automation initiierte Übergabe der Fahraufgabe an den Menschen durchführen und in Übernahmefunktionen, bei denen der Mensch diesen Wechsel initiiert. Grundsätzlich agieren beide lediglich binär und wechseln nur zwischen manuellem und assistiertem Modus. Während Übernahmefunktionen in der Regel softwareseitig nur ein „sanftes“ Abschalten des Assistenzsystems beinhalten, ist der Algorithmus für Übergabefunktionen umfangreicher. Letzteres ist bedingt durch die Tatsache, dass die Automation die Transition der Fahraufgabe initiiert und den menschlichen Fahrer zur Übernahme der Kontrolle auffordert. Damit der Mensch in diesem Fall geeignet reagieren kann, muss er informiert und geeignet unterstützt werden. Auf Basis der durch Umfoldsensoren erfassten Umgebung sowie der Fahrdynamiksensorik wird eine Übergabesituation berechnet, die dann an den

Fahrer kommuniziert wird. In Assistenzsystemen finden sich grundsätzlich folgende Funktionen: Warnfunktionen für kritische Situationen und an den geplanten Systemgrenzen der Automation sowie Übergabefunktionen bei einem Teilsystemausfall (Degradation). Jede dieser Funktionen verfolgt das Ziel, unabhängig von dem Automatisierungslevel eine kritische Fahrsituation zu detektieren. Warnfunktionen werden technisch dadurch realisiert, dass bestimmte Residuen berechnet und dann mit einem Schwellwert verglichen werden [Winner.2009]. Einige bilden diese Größen auch explizit über eine Regelbasis auf ein Kritikalitätsmaß ab. Hierbei kommen Fuzzy-Regelsätze [Börner.2006; Wang.2010], Neuronale Netze [Harris.1996; Chang.2008; Wu.2012], Clusterverfahren [Tapia.2013] oder Bayes'sche Netzwerke [Kawasaki.2004; Oh.2005] zum Einsatz. In weitergehenden Ansätzen wird der Fahrer über die Analyse der Lenkbewegung [Pilutti.1999; Torkkola.2004; Zhong.2007; Friedrich.2010], der Bedienung von Nebenbedienelementen wie Blinker, Radio etc. oder Innenraumüberwachungen [BLee.2012] in die Kritikalitätsbestimmung mit einbezogen. Demgegenüber realisieren Degradationsfunktionen Abschaltmechanismen, die aufgrund eines Teilsystemausfalls eine Übergabe an den Fahrer erfordern. Den Kern bilden entsprechende Diagnoseroutinen für die Detektion von Systemfehlern. Mehrere Veröffentlichungen offenbaren jedoch Schwierigkeiten bei der Übertragung dieser Regelungsfunktionen auf teil- und hochautomatisierte Systeme [Damböck.2012; Gold.2013; Merat.2014]. Sie zeigen, dass die Fähigkeit des Fahrers, nach einer Übernahmeaufforderung das Fahrzeug sicher zu steuern, noch stark beeinträchtigt sein kann, wenn er nach einer längeren Episode einer automatisierten Fahrt zur Übernahme aufgefordert wird. Da der Fahrer ab SAE Level 3 nicht mehr wie bisher verpflichtet ist, die Fahrzeugsituation durchgehend zu überwachen, befindet er sich zum Zeitpunkt der Übernahmeaufforderung wahrscheinlich in einem Zustand, in dem er nur unzureichende Informationen über die aktuelle Umgebungskonstellation besitzt. Ein solcher Mangel an Situationsbewusstsein kann zu späten, ausbleibenden oder falschen Reaktionen führen, welche wiederum sicherheitskritische Situationen hervorrufen können. Um dieses als Out-of-the-Loop-Performance-Problem [Endsley.1995] bezeichnete Phänomen zu vermeiden, ist eine engere Verzahnung zwischen Fahrer und Fahrzeug erforderlich.

Hierfür muss das bisher vorliegende Konzept der Übergabefunktionen, welches auf einer reinen Steuerung der Kontrollübergabe basiert, durch eine regelndes Verfahren ersetzt werden. Da aktuelle Funktionen hierfür nicht ausgelegt sind, werden in der Forschung seit einiger Zeit Verfahren untersucht, die durch eine gänzlich andere Herangehensweise geprägt sind. Sie haben eine engere Kooperation zwischen Fahrer und Fahrzeug zum Ziel, indem sie eine gleichzeitige Beeinflussung bzw. Steuerung des Fahrzeuges durch beide Partner erlauben und realisieren (Shared Control) [Abbink.2006; Winner.2009; Flad.2014]. Für die Lösung der Aufgabenstellung der Transition der

Fahraufgabe erscheint dieser Ansatz vielversprechend, da die Erwartung besteht, durch die Kenntnis der Aktivitäten des Menschen im Fahrzeug sowohl die Kontrolle als auch die Aufmerksamkeit und die Reaktionsfähigkeit des Fahrers gezielt regeln zu können. Allerdings sind auch diese Ansätze noch in einem frühen Stadium der Entwicklung; weder werden sie ganzheitlich umgesetzt noch ermöglichen sie eine durchgängige Adaption an die Reaktion des Fahrers. Aus diesem Grund ist ein Ansatz notwendig, mit dem der Fahrer im Rahmen einer kooperativen Transitionsphase sicher an die Fahraufgabe herangeführt wird. Hierfür muss die Interaktion zwischen den Kooperationspartnern modelliert und für die Gestaltung der Transition berücksichtigt werden. Ein solches Konzept, inklusive der Möglichkeit die Übernahmebereitschaft des Menschen zur Laufzeit zu bestimmen, wurde vom IRS im Rahmen des Projekts PAKoS entwickelt, umgesetzt und mit Hilfe von Fahrsimulatorstudien validiert.

### 1.5. Zusammenarbeit mit anderen Stellen

Aufgrund der interdisziplinären Fragestellung des Projekts PAKoS bestand der gesamte Projektverbund aus elf Partnern (Karlsruher Institut für Technologie (KIT) (Koordinator), Technische Universität München (TUM), Fraunhofer Gesellschaft – IOSB, Robert Bosch GmbH, BMW AG, Spiegel Institut Mannheim GmbH & Co. KG, Videmo Intelligente Videoanalyse GmbH & Co. KG, mVISE AG, Forschungszentrum Informatik (FZI), B.I.G., Stadtmobil CarSharing).

Neben dem obligatorischen Austausch mit der deutschen Fachcommunity (u. a. auf den Vernetzungstreffen der Förderinitiative des BMBF, der AUTOREG Konferenz und den Workshops der Profilregion Karlsruhe) erfolgte auch ein reger internationaler Austausch. Hierbei besonders zu nennen ist die Forschungsgruppe um Prof. Abbink an der TU Delft und die japanische Forschungscommunity um die Professoren Wada (Ritsumeikan University) und Itoh (University of Tsukuba).

Darüber hinaus ist die enge Zusammenarbeit zwischen dem CVHCI und dem Fraunhofer IOSB zu erwähnen, die zu der erfolgreichen Sammlung des Drive&Act-Datensatzes geführt hat. Auch methodisch haben sich die zwei Forschungsgruppen positiv ergänzt, da das IOSB Verfahren basierend auf der Körperpose entwickelte, sprich Machine-Learning-Verfahren mit einer Zwischendarstellung von Merkmalen, wohingegen das CVHCI die End-to-End-Methoden basierend auf faltenden neuronalen Netzen untersuchte und erweiterte.

## 2. Eingehende Darstellung

Im Folgenden wird die vorangegangenen Kurzdarstellung vertieft. Dies schließt u. a. eine eingehende Darstellung der entwickelten Methoden und der erzielten Ergebnisse mit ein.

### 2.1. Verwendung der Zuwendung und erzielte Ergebnisse

Die obige Kurzdarstellung des Projekts PAKoS verdeutlicht, dass das KIT die Fragestellungen der Fahrerbeobachtung sowie der Transition der Fahraufgabe adressierte. Die visuelle Erfassung des Fahrzeuginnenraums und insbesondere die Erkennung der Aktivitäten des Fahrers ist hierbei mit der erstgenannten Problemstellung verknüpft. Sie bildet die Grundlage für die Individualisierung und Adaption der hochautomatisierten Fahrfunktion sowie der kooperativen Transition. Die Entwicklung eines Systems für eine sichere Übergabe der Kontrolle des Fahrzeuges von der Automation zurück an den menschlichen Fahrer korrespondiert mit der zweiten vom KIT untersuchten Fragestellung. Hierbei muss insbesondere die reduzierte mentale Bereitschaft des Fahrers nach einer längeren rein automatisierten Fahrt, in der er Nebentätigkeiten nachgegangen ist, berücksichtigt werden. Die im Rahmen des Projektes entwickelten Methoden und die erzielten Ergebnisse sollen im Folgenden näher betrachtet werden, gegliedert nach den beiden adressierten Aufgabenstellungen.

#### 2.1.1. Visuelle Fahrererkennung

Die vom CVHCI entwickelten Verfahren zur Aktivitätserkennung basieren auf Verfahren des Deep Learning, sprich tiefen neuronalen Netzen, deren Performance stark von der Menge der zur Verfügung stehenden Daten abhängt. Deshalb wird in diesem Abschnitt zunächst der in PAKoS generierte und nun öffentlich zugängliche Drive&Act-Datensatz vorgestellt. Daran anschließend erfolgt die Erklärung der entwickelten End-to-End-Methoden für die Aktivitätserkennung.

##### 2.1.1.1. Erstellung des Drive&Act-Datensatzes

Um Deep-Learning-Modelle für die Aktivitätserkennung trainieren zu können, wird eine große Anzahl an Daten benötigt. Dabei beteiligte sich KIT an der Erstellung eines Trainingsdatensatzes zu Nebentätigkeiten im Fahrzeuginnenraum, insbesondere an der Konzeption, Erstellung des Versuchsprotokolls, Bereitstellung der Probanden, Durchführung der Datenaufzeichnung und Annotation der Daten. Gemeinsam mit dem Fraunhofer IOSB wurde die Datensammlung im Fahrsimulator mit unterschiedlichen Szenarien der manuellen sowie autonomen Fahrt und 15 Versuchspersonen durchgeführt. Dabei wurden ungefähr 14 Stunden Videomaterial aufgezeichnet,

synchron in sechs unterschiedlichen Ansichten mit Farb-, Tiefen-, und Infrarot-Daten. Die Probanden wurden dazu aufgefordert, mehrere Aufgaben zu lösen (z. B. mit dem Laptop das Wetter recherchieren und per SMS versenden). Dabei wurden, während jeder Fahrt, vier unerwartete Übernahmeaufforderungen ausgelöst, infolgedessen die Fahrt manuell weitergeführt wurde. Abb. 3 zeigt die grundlegenden Statistiken von *Drive&Act* und vergleicht den Datensatz mit existierenden Benchmarks. *Drive&Act* ist somit der erste große Datensatz für die Aktivitätserkennung im Kontext des autonomen und manuellen Fahrens [Martin.2019b]. Im Weiteren soll der Datensatz und dessen Annotation detaillierter betrachtet werden.

	SoA conven. AR		Multi-mod. AR		Driver Activity Recognition Datasets					Drive&Act
	Kinetics [7]	NTU [43]	HEH [36]	Ohn et al. [35]	Brain4Cars [19]	D.P.-Night [50]	D.P.-Real [50]	AUC-D.D. [2]	2019	
Year	2017	2016	2014	2014	2015	2016	2016	2017/18	2019	
Publicly available	✓	✓	✓	–	✓	–	–	✓	✓	
Manual driving	–	–	✓	✓	✓	✓	✓	✓	✓	
Autonomous driving	–	–	–	–	–	–	–	–	✓	
RGB/Grayscale	✓	✓	✓	✓	✓	✓	✓	✓	✓	
Depth	–	✓	✓	N/A <sup>b</sup>	–	–	–	–	✓	
NIR	–	✓	–	–	–	✓	–	–	✓	
Skeleton	–	✓	–	–	–	–	–	–	✓	
Video	✓	✓	✓	N/A <sup>b</sup>	✓	✓	✓	N/A <sup>b</sup>	✓	
N° images	>76M	4M	N/A <sup>b</sup>	11K	2M	29K	18K	17K	> 9.6M	
N° synchron. views	1	3	1	2	2	1	1	1	6	
Resolution	N/A <sup>c</sup>	1920×1080 <sup>b</sup>	680×480	N/A <sup>b</sup>	1920×1088	640×480	640×480	1920×1080	1280×1024 <sup>d</sup>	
N° subjects	N/A <sup>b</sup>	40	8	4	10	20	5	31	15	
Female / male	N/A <sup>b</sup>	N/A <sup>b</sup>	1 / 7	1 / 3	N/A <sup>b</sup>	10 / 10	N/A <sup>b</sup>	9 / 22	4 / 11	
N° Classes	400	60	19	3	5	4	4	10	83	
Multi-level annot.	–	–	–	–	–	–	–	–	✓	
N° Levels	1	1	1	1	1	1	1	1	3	
Continuous labels	–	–	–	N/A <sup>b</sup>	–	✓	✓	N/A <sup>b</sup>	✓	
Object annot.	✓	–	–	–	–	–	–	–	✓	

<sup>a</sup> RGB resolution, IR/Depth resolution is 512×424  
<sup>b</sup> information not provided by the authors  
<sup>c</sup> variable resolution  
<sup>d</sup> NIR-camera resolution

Abbildung 3: Statistiken des *Drive&Act*-Datensatzes und Vergleich mit anderen existierenden Benchmarks [Martin.2019b].

### Identifikation relevanter Aktivitäten

Ein wichtiger Schritt für die Datensammlung war die Identifikation relevanter Aktivitätskategorien und ihre Verfeinerung in *Handlungsatome*, die aufgezeichnet und anschließend von den Algorithmen erkannt werden. Der resultierende Aktivitätskatalog wurde in drei Schritten erstellt: Analyse der existierenden Fahrerstudien, Befragung der Projektpartner und die anschließende Einschätzung der Machbarkeit.

- **Analyse der Fahrerstudien.** Die erste Aktivitätsliste und die dazugehörige Bewertung wurden durch eine Revision bereits publizierter Arbeiten zu Fahrer Nebentätigkeiten und ihrer Auswirkung auf die Aufmerksamkeit/Unfallgefahr erstellt. Häufig aufgeführte Nebentätigkeiten aus unterschiedlichen Studien wurden in einem Aktivitätskatalog zusammengefasst und in zehn Aktivitätskategorien unterteilt: Essen und Trinken, Kleidung und Hygiene, Interaktion mit fahrzeuginternen Geräten, Interaktion mit externen Geräten und Objekten, Interaktion mit der Umgebung außerhalb des Fahrzeugs, Rauchen, selbstbezogene



Aktivitäten, Interaktion mit Personen und Haustieren, kritische Situationen und fahrbezogene Tätigkeiten.

- **Befragung der Projektpartner.** Als nächstes wurde eine Befragung und Bewertung der Aktivitätsliste durch die anwendungsnahen Projektpartner durchgeführt. Fünf Partner haben die Aktivitäten auf einer Zahlenskala bewertet. Darüber hinaus wurden Vorschläge für weitere Aktivitäten und sonstiges Feedback aufgenommen. Durch statistische Auswertung der Ergebnisse (Bewertungsmedian > Schwellwert) wurden relevante Tätigkeiten identifiziert.
- **Überprüfung der Machbarkeit.** Anschließend wurde eine Machbarkeitsanalyse der Aktivitäten (z. B. Schwierigkeit und Vertretbarkeit der Umsetzung der Aktivität „Rauchen“) gemeinsam mit dem Fraunhofer IOSB durchgeführt. Dies resultierte in dem endgültigen Zielkatalog der Aktivitäten. Insgesamt wurden 64 Aktivitäten identifiziert. Davon sind 30 mit einer hohen und 13 mit einer geringeren Priorität (Partnerumfrage) als technisch machbar eingestuft, 9 wurden als ein Spezialfall (z. B. Schlafen) identifiziert und 12 Aktivitäten wurden aufgrund ihrer schwierigen Umsetzung bei der Datensammlung ausgeschlossen (z. B. Rauchen).

### Hierarchisches Annotationsschema

Um den Zusammenhang zwischen den komplexeren Aktivitäten und primitiven Handlungsatomen zu untersuchen, wurde ein dreistufiges Annotationsschema entwickelt. Es umfasst die *Aufgabe* bzw. den *Kontext*, die *Aktivitäten* und die *primitiven Aktionen (Handlungsatome)*. Zusätzlich wurde der Fahrzustand in Bezug auf das Lenkrad annotiert (z. B. eine Hand am Lenkrad), jedoch nur als eine zusätzliche Information betrachtet. Während die abstrakte Aufgabe den Probanden vorgegeben wurde, war ihnen die Ausführung dieser und damit insbesondere die Ausführung der Handlungsatome frei überlassen. Ein Handlungsatom ist definiert durch ein Triplet aus Aktion, Objekt (wenn zutreffend) und Ort. Abb. 4 zeigt einige Beispiele der hierarchischen Annotation.

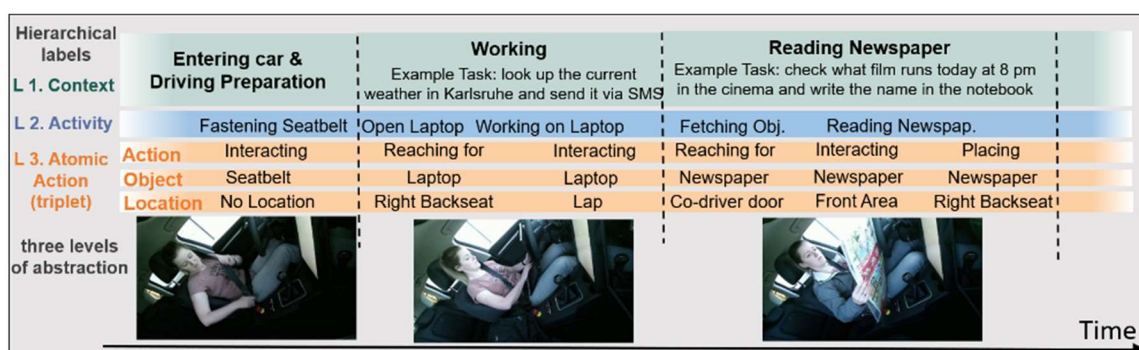


Abbildung 4: Beispiele der hierarchischen Annotation des Drive&Act-Datensatzes.

## Analyse des Datensatzes

Die erfassten Verhaltensweisen sind in ihrer Komplexität und Dauer sehr unterschiedlich. Selbst wenn nur eine einzige Hierarchiestufe betrachtet wird (z. B. die feingranularen Aktivitäten). So dauert beispielsweise der Aktivitätsabschnitt einer Person, die eine Zeitschrift liest, oft fast eine Minute, während andere Aktivitäten im Durchschnitt nur wenige Sekunden dauern, wie z. B. das Drücken der Taste zur Aktivierung der Fahrzeugautomation. Die Kategorien sind auch in Bezug auf ihre Häufigkeit im Datensatz ungleichmäßig verteilt, was für Echtzeitanwendungen charakteristisch ist, da bestimmte Ereignisse von Natur aus seltener sind. Eine Übersicht darüber, wie oft eine Aktion im Datensatz auftritt und wie lang sie im Durchschnitt dauert, ist in Abb. 5 dargestellt.

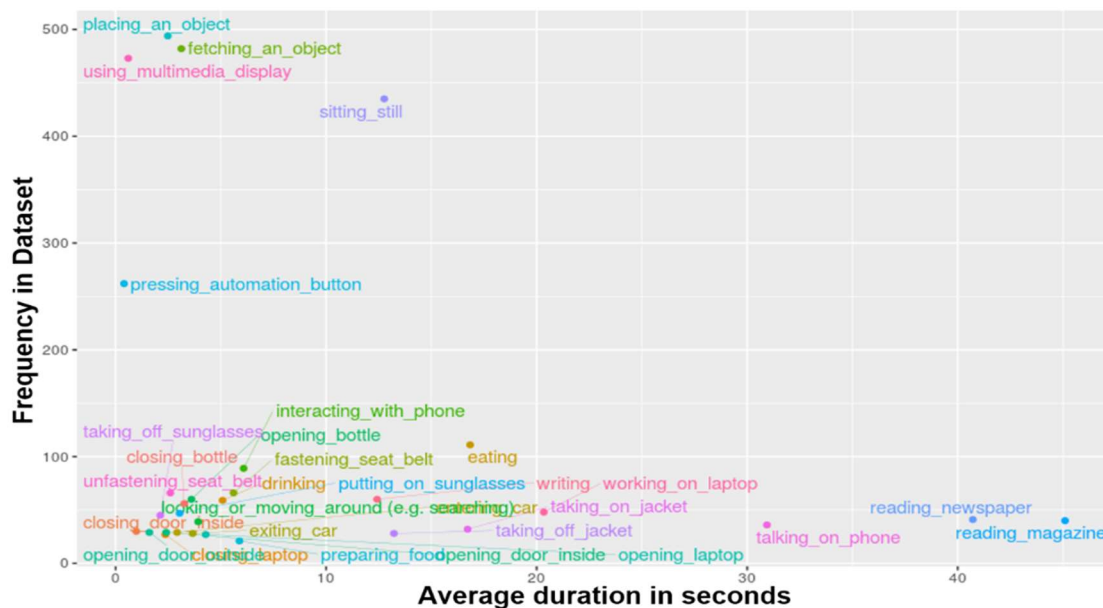


Abbildung 5: Durchschnittliche Dauer und Häufigkeit einzelner Aktivitäten im Drive&Act-Datensatz.

Darüber hinaus kann eine starke Individualität in den Verhaltensweisen beobachtet werden. Verschiedene Menschen führen ähnliche Aufgaben auf sehr unterschiedliche Weise aus. Einige Menschen bewegen sich langsamer als andere oder führen verschiedene Schritte aus, um das gleiche Ziel zu erreichen. Die Untersuchung derartiger individueller Unterschiede, die in Abb. 6 am Beispiel des

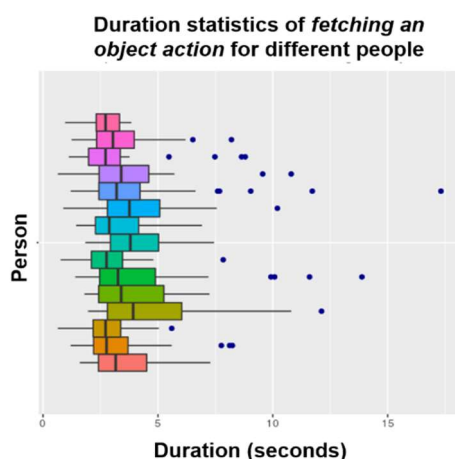


Abbildung 6: Menschen führen gleiche Aktivitäten auf unterschiedliche Art und Weise aus. Der Boxplot veranschaulicht die Dauer ein **Objekt zu holen**, gruppiert nach Personen (blaue Punkte stellen Ausreißer dar). Während die Aktion bei einigen Personen nur wenige Sekunden dauert, haben andere Fahrer häufig Ausreißer mit sehr langen Zeitdauern (über 15 Sekunden).



Holens eines Gegenstandes dargestellt sind, stellt eine wichtige zukünftige Forschungsrichtung dar. Die Personalisierung von Erkennungsmodellen und ihre Online-Anpassung an die charakteristischen Bewegungsmuster des Nutzers kann die Robustheit der Verfahren erhöhen.

Für die Auswertung werden die Videoaufnahmen in drei Sekunden lange Segmente unterteilt. Diese Videosegmente mit den entsprechenden Annotationen werden zum Training und zur Validierung der Erkennungsmodelle verwendet. Zentrale Aufgabe ist es daher, jedem 3-Sekunden-Video block die richtigen Klassen auf allen Hierarchieebenen zuzuordnen. Abb. 7 veranschaulicht die Verteilung der Samples für jedes mögliche Label in unserem Datensatz. Eine deutlich unausgewogene Verteilung der verschiedenen Klassen ist vorhanden, da bestimmte Aktionen (z. B. Laptop aus dem Rucksack nehmen) selten sind, während andere (z. B. stillsitzen) sehr häufig vorkommen.




Abbildung 7: Häufigkeit der einzelnen Aktivitäten und Handlungsatome auf Basis der 3-секündigen Videosegmente [Martin.2019b].

### 2.1.1.2. Algorithmen zur Fahreraktivitätserkennung

Auf Basis des erläuterten Datensatzes wurde eine Pipeline zur videobasierten Fahreraktivitätserkennung umgesetzt. Da der Drive&Act-Datensatz allerdings erst im Laufe von PAKoS, parallel zu den Erkennungsverfahren, entwickelt wurde, wurden die Verfahren zunächst an öffentlichen Datensätzen zur allgemeinen Aktivitätserkennung (z. B. basierend auf YouTube-Videos) trainiert und getestet [Roitberg.2018a; Roitberg.2018b; Roitberg.2019; Gebert.2019]. Anschließend wurden die Verfahren auf Drive&Act übertragen und evaluiert [Martin.2019b; Roitberg.2020a; Roitberg.2020b; Reiß.2020b].

Die Algorithmen zur Aktivitätserkennung lassen sich in zwei Gruppen unterteilen: (1) Methoden, die auf manuell entworfenen Merkmalen basieren und (2) End-to-End-Methoden, die auf tiefen faltenden neuronalen Netzen (engl. Convolutional Neural Networks, CNNs) basieren (siehe Vergleich in Abb. 8). Während der Fokus des CVHCI auf den Verfahren des Deep Learning liegt, wurden zum Vergleich

ebenfalls merkmalsbasierte Methoden, welche Bewegungstrajektorien (Improved Dense Trajectories) nutzen, umgesetzt. Im Folgenden werden die wichtigsten implementierten Architekturen beschrieben.

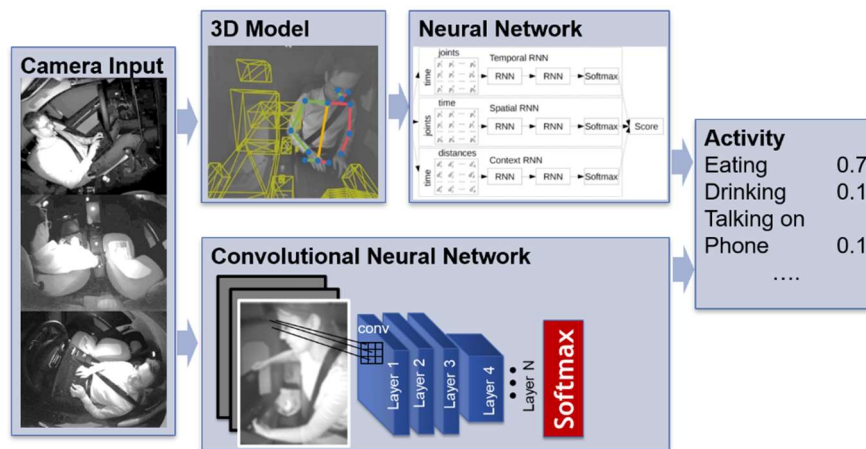


Abbildung 8: Die klassische Machine-Learning-Pipeline (oben) dominiert seit Jahren die Fahrerbeobachtung und basiert auf manuell entworfenen Merkmalen (z. B. Bewegungstrajektorien oder Körperhaltung). Die neuen Deep-Learning-Ansätze (unten) lernen diese Merkmalsextraktion automatisch.

### Erkennung mit lokalen Merkmalsdeskriptoren

Merkmalsbasierte Methoden, die im Bereich der Fahreraktivitätserkennung seit Jahrzehnten verbreitet sind, folgen der klassischen Pipeline des maschinellen Lernens (vgl. Abb. 8 oben). Als erstes wird ein Merkmalsvektor, der die Eingabedaten repräsentiert, berechnet. Die Art und Weise der Datenverarbeitung wird dabei manuell definiert. Im zweiten Schritt wird der Merkmalsvektor einem Machine-Learning-Verfahren (z. B. Support Vector Machine) zur Klassifikation übergeben. Ein derartiges Vorgehen wurde im Rahmen von PAKoS als erste Vergleichsmethode für die Erkennung der Fahreraktivitäten umgesetzt. Als lokale Merkmale wurden die Bewegungstrajektorien genutzt (z. B. basierend auf Dense Trajectories bzw. Fast Dense Trajectories, vgl. Abb. 9), die durch die Berechnung des optischen Flusses bestimmt werden. Da die Anzahl der Bewegungstrajektorien unterschiedlich sein kann und ein Machine-Learning-Algorithmus jedoch einen Vektor fester Größe als Input benötigt, werden die Trajektorienvektoren mittels Bag-Of-Words-Verfahren aggregiert. Dabei werden die Trajektorienvektoren in Codewörter konvertiert, wodurch ein Codebuch (analog zu einem Wörterbuch) entsteht. Ein Codewort kann als Vertreter mehrerer ähnlicher Trajektorien betrachtet werden. Eine einfache Methode ist die Durchführung von k-Means-Clustering über alle Vektoren. Codewörter werden dann als die Zentren der gelernten Cluster definiert. Die Anzahl der Cluster entspricht der Codebuchgröße. Anschließend wird die Aktivität, z. B. mithilfe eines Histogramms der

Codewörter, dargestellt und an einen Klassifikator (z. B. Support Vector Machine oder Random Forest) für die finale Prädiktion übergeben.

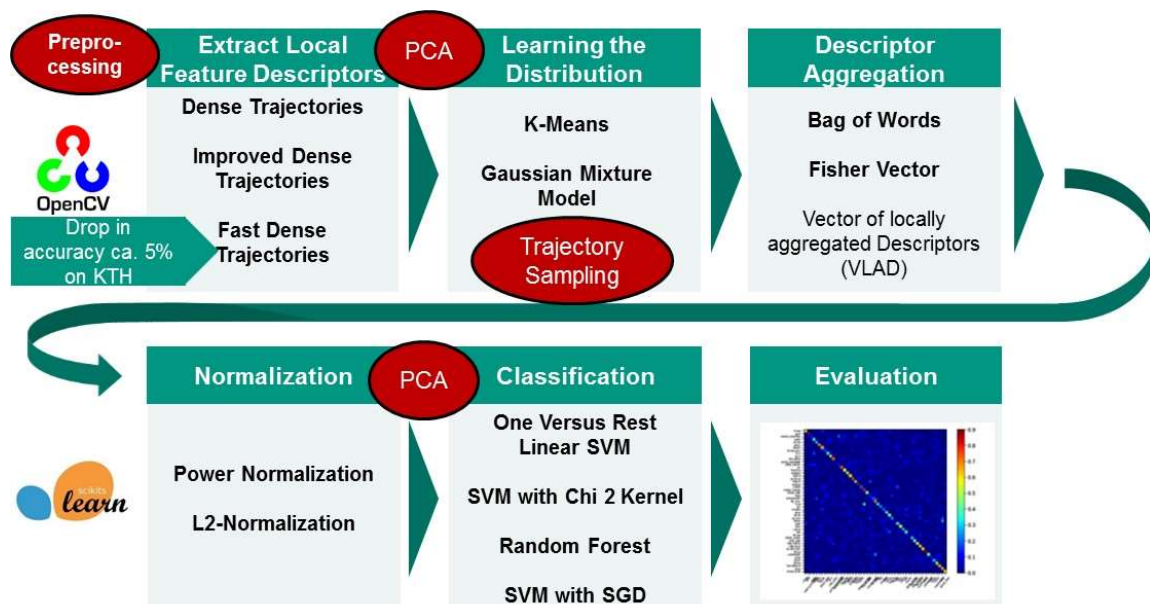


Abbildung 9: Überblick über die Erkennungspipeline basierend auf lokalen Merkmalen (Bewegungstrajektorien).

### Erkennung mit End-to-End-Methoden

Im Kontext der vorwiegend adressierten End-to-End-Methoden wurde eine Deep-Learning-basierte Pipeline basierend auf 3D-Faltungen zur Aktivitätserkennung implementiert. Mehrere Backbone-Architekturen aus dem Stand der Forschung (**C3D**, **3D ResNet**, **I3D**, **Pseudo 3D ResNet**) wurden umgesetzt und zunächst an öffentlichen Datensätzen trainiert sowie getestet [Roitberg.2018a; Roitberg.2018b; Roitberg.2019; Gebert.2019], da der PAKoS-Datensatz erst gegen Ende 2018 zur Verfügung stand. Um einzuschätzen, ob der Transfer in die Fahrzeugdomäne funktioniert, wurde die Pipeline auf einem öffentlich verfügbaren Benchmark zur Manöverprädiktion mittels Fahrerbeobachtung (Brain4Cars-Datensatz) evaluiert und erreichte dabei vergleichbare Ergebnisse zum Stand der Forschung [Gebert.2019]. Zusätzlich wurde dabei eine neue Methode vorgestellt, die ein neuronales Netzwerk für die Berechnung des optischen Flusses mit einem 3D ResNet sowie einem rekurrenten neuronalen Netz (LSTM) vereint, was die Erkennungsrate deutlich verbessert. Von den Architekturen, die auf Drive&Act erprobt wurden, zeigt das Inflated 3D ConvNet [Carreira.2017] die besten Ergebnisse [Martin.2019b; Roitberg.2020b]. Diese neuronale Netzwerkarchitektur verwendet ein Videosegment mit 64 Frames und einer Auflösung von 224×224 als Input und behandelt räumliche und zeitliche Dimensionen durch 3D-Faltungen sowie Pooling-Operationen. I3D ist besonders effizient durch mehrere charakteristische Inception-Module (kleine Sub-Netzwerke, die 5×5×5-, 3×3×3- und 1×1×1-Faltungsoperationen parallel ausführen und die Ausgabe verknüpfen). Ein wesentliches

Merkmal des Inception-Moduls sind mehrere  $1 \times 1 \times 1$ -Faltungen, die die Dimension reduzieren und die Anzahl der Dimensionen somit geringhalten, was für Echtzeitanwendungen von großer Bedeutung ist. Das komplette I3D-Netzwerk besteht aus 27 Schichten mit der in Abb. 10 dargestellten Übersicht (zu beachten ist, dass die neun Inception-Module selbst zwei Schichten tief sind).




Abbildung 10: Überblick über die Inflated 3D Net Architecture, welche die besten Erkennungsergebnisse liefert.

Bei den ersten Erprobungen auf Benchmarks zur allgemeinen Aktivitätserkennung (UCF-101, HMDB-51) zeigte sich eine klare Überlegenheit der Deep-Learning-basierten Ansätze (Steigerung  $>15\%$  auf HMDB-51). Infolgedessen fokussierte das CVHCI die End-to-End-Verfahren und verglich diese, im Kontext der Fahreraktivitätserkennung und dem Drive&Act-Datensatz, mit merkmalsbasierten Methoden, die die Körperpose nutzen und die vom Fraunhofer IOSB entwickelt wurden (vgl. Tab. 1).

Tabelle 1: Ergebnisse (Erkennungsraten) unterschiedlicher Erkennungsmodelle auf dem in PAKoS generierten Drive&Act-Datensatz (Level 2, feingranulare Aktivität). Die End-to-End-Methoden basierend auf tiefen neuronalen Netzen zeigen eine deutliche Überlegenheit

Typ	Modell	Validierungsdaten	Testdaten
Baseline	Zufall	2,94 %	2,94 %
Merkmalsbasiert	Interior	45,23 %	40,30 %
	Pose	53,17 %	44,36 %
	Multi-Stream	66,67 %	46,95 %
End-to-End	C3D	49,54 %	43,41 %
	P3D ResNet	55,04 %	45,32 %
	I3D Net	<b>69,57 %</b>	<b>63,64 %</b>

Die posenbasierten Verfahren nutzen eine rekurrentes neuronales Netz für die Enkodierung des Skeletts und die Handhabung der zeitlichen Dimension. Eine Vermutung für die schlechtere Performance dieser Verfahren ist das Fehlen der Information über die Objekte, mit denen eine Interaktion erfolgt. Da CNN-basierte Methoden komplette Bilder als Eingabe verarbeiten, geht diese Information im Fall der End-to-End-Methoden nicht verloren. Diese Argumentation wird auch durch die folgende qualitative Auswertung gestützt.

Neben den quantitativen Ergebnissen in Tab. 1 veranschaulicht Abb. 11 die qualitativen Resultate der Vorhersagen des Inflated 3D Net, wobei die Videoregion mit der höchsten Auswirkung auf die Entscheidung hervorgehoben ist. Die Analyse zeigt die besondere Bedeutung der Hände des Fahrers, was auf deren starken Involvierem in die Objektmanipulationen zurückzuführen ist.

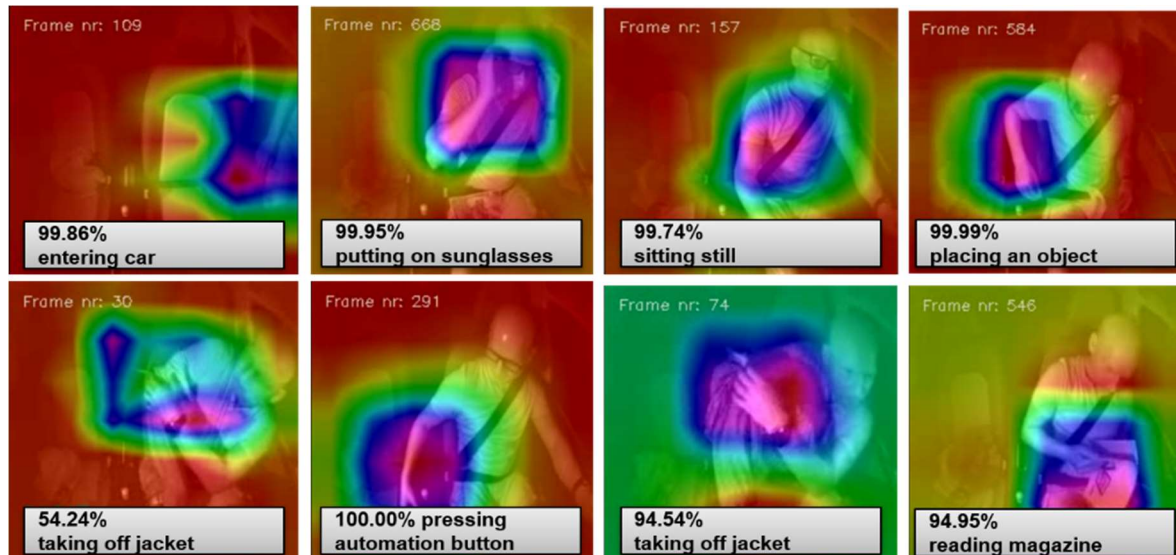


Abbildung 11: Beispiele für die Ergebnisse der CNN-Vorhersage mit der Visualisierung von Bildregionen mit den höchsten Aktivierungen des neuronalen Netzes. Die Aufmerksamkeit des Netzes ist oft auf die Hände des Fahrers gerichtet [Roitberg.2020b].

## Multimodale Fusion

Multimodalität ist ein wichtiges Konzept bei der Fahrerbeobachtung, da verschiedene Sensoren ihre individuellen Schwächen und Stärken haben. So sind beispielsweise Tiefensensoren weniger anfällig für Änderungen der Beleuchtung, während farbbasierte Modelle von einem Vor-Training auf großen Computer-Vision-Datensätzen profitieren können, da diese oft auf Farbbildern basieren. Die häufigste Strategie für die Umsetzung einer multimodalen Erkennung ist die Realisierung einer multimodalen Fusion mit dem *Late-Fusion*-Konzept, d. h. separates Training einzelner Netzwerke für jede Modalität und anschließende Verbindung über die Mittelung der resultierenden Ergebnisse auf der letzten Schicht. Tab. 2 zeigt die Erkennungsergebnisse für die einzelnen Modalitäten sowie das Ergebnis ihrer Fusion. Die Datengrundlage bildet erneut Level 2 (feingranulare Aktivitäten) des Drive&Act-Datensatzes. Der Informationsaustausch zwischen den Datenströmen stellt sich insgesamt als äußerst vorteilhaft heraus. So kann mit der Kombination aller Ansichten eine Erkennungsrate von 69,03% erzielt werden.

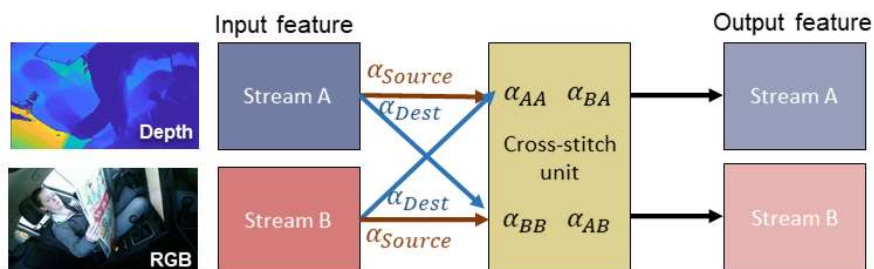


Die beschriebene späte Fusion der Daten ist zwar einfach umzusetzen und überraschend effektiv, berücksichtigt jedoch die hohe Korrelation der Eingangsdaten auf den ersten Schichten des neuronalen Netzes nicht. Folglich wurden mehrere Strategien erprobt, um die Informationen zwischen den Modalitäten bereits in früheren Netzwerkstadien auszutauschen.

*Tabelle 2: Ergebnisse (Erkennungsraten) der multimodalen Erkennung. Vergleich unterschiedlicher Ansichten und ihrer Kombination [Martin.2019b]. Fusion mehrerer Sensoren und Ansichten führt zu besseren Erkennungsergebnissen.*

Sensor	Ansicht	Testdaten
Infrarot	Vorne oben	63,64 %
	Rechts oben	60,68 %
	Hinten	54,34 %
	Frontal	42,98 %
	Links oben	62,83 %
	<b>Fusioniert</b>	<b>67,17 %</b>
Kinect Farbe	Rechts oben	62,95 %
Kinect Tiefe		60,52 %
Kinect Infrarot		64,98 %
<b>Fusioniert</b>		<b>68,51 %</b>
<b>Alle fusioniert (späte Fusion)</b>		<b>69,03 %</b>

Eine Möglichkeit für eine solche Fusion besteht darin, zunächst getrennte Ströme für die Modalitäten in frühen Schichten zu verwenden und sie dann in einem späteren Stadium über 1x1x1-Faltungen zu einem gemeinsamen Modell zu verschmelzen. In diesem Fall geschieht der Fusionspunkt jedoch auf einer einzigen Netzwerkschicht und muss manuell gewählt werden. Ein besserer Weg, die gewünschte multimodale Fusion zu erreichen, ist *der gleichzeitige Austausch von Wissen auf mehreren Schichten*. Dies kann über sogenannte Cross-stitch Units erreicht werden. Diese können mittels Training lernen, wie die Aktivierungen beider Netze optimal kombiniert werden können, wobei für jede Eingabemerkmalsskarte ein Gewichtsparameter gelernt wird (vgl. Abb. 12). Ursprünglich für das Multi-



*Abbildung 12: Gleichzeitige multimodale Fusion auf mehreren Schichten. Cross-stitch Units ermöglichen den Informationsaustausch in jeder Netzwerktiefe, indem eine optimal gewichtete lineare Kombination der Merkmale erlernt wird [Roitberg.2019].*

Task-Lernen konzipiert [Misra.2016], ermöglichen es Cross-stitch Units, die zwei Aktionserkennungsnetzwerke gleichzeitig auf mehreren Ebenen zu verbinden [Roitberg.2019]. Dieser Wissensaustausch wurde auf “ChaLearn Isolated Gesture Recognition” (IsoGD) für multimodale Gestenerkennung evaluiert und führte zu besseren Erkennungsergebnissen. Insgesamt erreichte unser Verfahren mittels Cross-stitch Units eine Genauigkeit von 79,8% bei zehn möglichen Gesten (4,6% besser, als die späte Fusion).

## Open-World-Erkennung

Neben der Entwicklung von Deep-Learning-basierten Ansätzen für die Fahreraktivitätserkennung war ein weiteres wichtiges Ziel die Untersuchung und Berücksichtigung der Herausforderungen *realer* Anwendungen im Automotive-Bereich. Dies schließt u. a. die Möglichkeit der Nutzung weniger anwendungsspezifischer Trainingsdaten mit ein, aber auch die Berücksichtigung der Unsicherheiten der Verfahren des maschinellen Lernens sowie das Open-World-Szenario (neue Aktivitäten, welche nicht im Trainingsdatensatz enthalten sind, können jederzeit auftreten).

Infolgedessen wurden im Rahmen von PAKoS *Transfer-Learning*-Verfahren umgesetzt, bei denen ein neuronales Netz zunächst auf einem großen öffentlich verfügbaren Datensatz trainiert wird und anschließend die gelernten allgemeinen Strukturen auf die anwendungsspezifischen Daten (z. B. Fahrzeugdomäne) mittels Fine Tuning übertragen werden. Alternativ kann eine Übertragung auf neue Aktivitätsklassen durch semantischen Transfer mit Hilfe des sogenannten Zero-Shot Learning erfolgen [Roitberg.2018b; Reiß.2020a; Reiß.2020b].

Da Deep-Learning-Modelle die Erkennungsrate auf statischen Datensätzen optimieren („closed set“), neigen sie dazu, ihre Sicherheit stark zu überschätzen. Dieser Aspekt ist kritisch für die Anwendung, da die reale Welt stets dynamisch ist und neue, unbekannte Aktivitätsklassen jederzeit auftreten können („open set“). Für eine robuste Erkennung in der Fahrzeugdomäne, wurde deshalb ein neuer

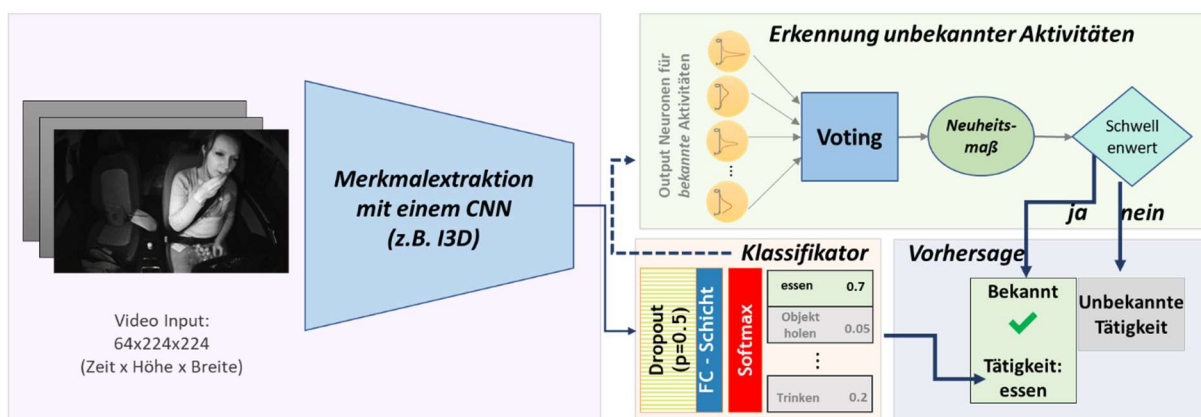


Abbildung 13: Entwickeltes Open-Set-Erkennungsframework basierend auf der Bayes'schen Unsicherheit der Output-Neuronen [Roitberg.2018a; Roitberg.2020b].

Algorithmus basierend auf Bayes'schen neuronalen Netzen mit Monte-Carlo Dropout entwickelt. Dieser ermöglicht sowohl die Erkennung bekannter Aktivitäten, als auch die Identifikation unbekannter Klassen und eine semantische Einordnung der unbekannteren Aktivitätsklassen mittels Zero-Shot Learning. Abb. 13 zeigt einen Überblick über die Methode zur Erkennung von Aktivitäten, die nicht im Trainingsdatensatz enthalten sind. Das entwickelte Erkennungsmodell zielt hierbei auf das Open-World-Szenario der Fahrerbeobachtung ab. Mittels Monte-Carlo Dropout entscheiden die individuellen Output-Neuronen über den Novelty Score, aus dem schließlich abgeleitet wird, ob die Aktivität bekannt oder neu ist. Der Algorithmus erreicht in der allgemeinen Aktivitätserkennung [Roitberg.2018a] und der Fahreraktivitätserkennung [Roitberg.2020a] Ergebnisse, die mit dem Stand der Forschung vergleichbar oder besser sind.

Tab. 3 zeigt die erzielten Ergebnisse auf dem Drive&Act-Datensatz. Die Fläche unter der ROC-Kurve des erzeugten Novelty Score dient als Bewertungsmetrik und in Tab. 3 sind der Mittelwert und die Standardabweichung über zehn zufälligen Datensatz-Splits angegeben. Während alle Modelle den Zufallsklassifikator übertreffen, zeigen die auf neuronalen Netzen basierenden Ansätze klare Vorteile, da selbst die alleinige Verwendung der Softmax-Wahrscheinlichkeit ein Gaussian Mixture Model (GMM) um 15,32% übertrifft. Die Erkennungsrate wird zusätzlich durch die Verwendung der entwickelten probabilistischen Ansätze (Bayesian I3D) verbessert. Die Nutzung der Unsicherheit *aller Ausgangsneuronen durch informierte Abstimmung* (Selective Voting) führt zu den besten Erkennungsraten sowohl für das Trainings-, als auch für das Validierungsset.

*Tabelle 3: Ergebnisse der entwickelten Open-Set-Erkennungsmethode. Ziel ist es, zu erkennen, ob die Aktivität aus dem Training bekannt oder neu ist. Die entwickelte Methode basierend auf Bayes'schen neuronalen Netzen führt zu den besten Ergebnissen auf Drive&Act [Roitberg.2020b].*

Methode	Validierungsdaten		Testdaten	
	ROC AUC	Standardabw.	ROC AUC	Standardabw.
<b>Konventionelle Methoden und Baselines</b>				
Zufall	50,00 %	-	50,00 %	-
Support Vector Machine (eine Klasse)	62,51 %	5,92 %	59,35 %	11,19 %
Gauß'sche Mischmodelle	68,84 %	6,97 %	65,73 %	7,09 %
Konventionelle Konfidenz des neuronalen Netzes	82,21 %	5,66 %	81,05 %	4,64 %
<b>Methoden basierend auf Bayes'schen neuronalen Netzen</b>				
Bayes'sche I3D - Prädiktive Varianz	83,10 %	5,47 %	82,69 %	4,36 %
Bayes'sche I3D - Prädiktiver Durchschnitt	84,60 %	4,50 %	83,60 %	3,93 %
Bayes'sche I3D – Selective Voting	<b>85,30 %</b>	<b>4,06 %</b>	<b>84,33 %</b>	<b>3,85 %</b>



### 2.1.1.3. Ergänzende Anmerkungen

Für die Integration der Erkennungssoftware in das Gesamtsystem, wurden die Projektpartner fortlaufend beim Schnittstellenentwurf unterstützt. Signale, die von der Erkennungskomponente geliefert werden, sowie ihre Wertebereiche wurden festgelegt und dokumentiert.




Abbildung 14: Beispiel der implementierten Kopfposenerkennung im Fahrzeuginnenraum.

Im Rahmen des Arbeitspaketes zur Gesichtserkennung des Fahrers, beschäftigte sich das KIT zudem mit Algorithmen zur Kopfposenbestimmung im Fahrzeuginnenraum [Schwarz.2017]. In diesem Zusammenhang wurde die Qualität moderner Verfahren (z. B. OpenFace [Baltrušaitis.2016]) bezüglich unterschiedlicher Ansichten im Fahrzeuginnenraum untersucht und bewertet (vgl. Abb. 14).

### 2.1.1.4. Zusammenfassung

Im Rahmen von PAKoS beschäftigte sich die KIT, als erste von zwei Hauptfragestellungen, mit der videobasierten Erkennung der Aktivität des Fahrers mittels tiefer neuronaler Netze. Eine derartige Einschätzung des Fahrerzustandes ist essentiell für eine intuitive und sichere Zusammenarbeit zwischen Mensch und Fahrzeug. Der zunehmende Automatisierungsgrad erhöht die Freiheit des Menschen und führt dazu, dass der Fahrer häufiger ablenkende Verhaltensweisen zeigt. Methoden der Bildverarbeitung ermöglichen es, die Situation im Fahrzeug automatisch zu interpretieren und Rückschlüsse über die Aufmerksamkeit des Fahrers zu ziehen. Neben der Identifizierung der Fahrerablenkung aus Sicherheitsgründen kann die Aktivitätserkennung auch den Komfort erhöhen, wie die Anpassung der Fahrweise beim Trinken.

Da das Training von Deep-Learning-Modellen viele annotierte Trainingsdaten benötigt, wurde vom KIT gemeinsam mit dem Fraunhofer IOSB *Drive&Act* - erster großer Datensatz zur Erkennung der Fahrer Nebentätigkeiten während der autonomen und manuellen Fahrt - aufgenommen und der Öffentlichkeit frei zur Verfügung gestellt. Ein wichtiger Schritt war die Identifikation relevanter Fahreraktivitäten, die erkannt werden müssen, was in drei Schritten erfolgte: (1) Analyse existierender Fahrerstudien, (2) Durchführung und Auswertung einer Befragung der PAKoS-Partner und (3) die Analyse der Machbarkeit. Um den Zusammenhang zwischen den komplexeren Aktivitäten und primitiven Handlungsatomen zu untersuchen, wurde ein dreistufiges Annotationschema entwickelt. Insgesamt wurden 15 Versuchspersonen und ungefähr 14 Stunden Videomaterial in sechs

unterschiedlichen Ansichten (Infrarot-, Farb- und Tiefenbilder) aufgenommen und mit den entwickelten hierarchischen Annotationen versehen.

Ein wichtiger weiterer Beitrag ist die Erkennungspipeline für die Fahrerbeobachtung. Mehrere Deep-Learning-Methoden basierend auf 3D-Faltungen (z. B. Inflated 3D CNN, C3D, P3D) wurden für die Fahreraktivitätserkennung untersucht und systematisch verglichen. Die Ergebnisse zeigen eine Überlegenheit der Deep-Learning-basierten Architekturen gegenüber den traditionellen merkmalsbasierten Ansätzen, wobei Inflated 3D CNN die besten Ergebnisse hervorrief. Der letzte Fokus der Forschungsaktivitäten im Kontext der Fahrerbeobachtung waren die Herausforderungen realer Anwendungen im Automotive-Bereich, u. a. eine geringe Anzahl annotierter Trainingsdaten, die Unsicherheiten von Deep-Learning-Modellen sowie die multimodale Erkennung. Es wurden neue Methoden für die Open-World-Erkennung (das Erkennungsmodell muss unsichere Fälle/noch unbekannte Aktivitäten einschätzen können) und für die Fusion unterschiedlicher Modalitäten mittels Cross-stitch Units entwickelt. Darüber hinaus wurde das Anwendungsfeld der Modelle erweitert und z. B. für die Manöverprädiktion durch Fahrerbeobachtung (Brain4Cars-Datensatz) angepasst. Unsere Verfahren erreichen Stand-der-Forschung-Ergebnisse in der Drive&Act- und Brain4Cars-Testumgebung sowie auf den Open-Set-Benchmarks der HMDB-51 und UCF-101-Datensätze.

### 2.1.2. Kooperative Transition der Fahraufgabe

Wie in der Aufgabenstellung und dem Stand der Technik beschrieben, liegt der zweite Aufgabenbereich des KIT in der Entwicklung eines Systems zur kooperativen Transition der Fahraufgabe, welche den Fahrer auch nach der Übernahme der Bedienelemente noch unterstützt und ihn sicher an die Fahraufgabe, sprich die alleinige Kontrolle des Fahrzeuges, heranführt. Im Zusammenhang mit der Realisierung dieser Transitionsphase stellen sich grundsätzlich zwei Fragen. Zunächst muss geklärt werden, wie die Interaktion zwischen Mensch und Automatisierung so modelliert werden kann, dass das Framework den Übergang der Steuerung des Fahrzeuges zwischen beiden Partnern beschreiben kann. Zweitens muss die Frage beantwortet werden, wie der genaue Verlauf der Transition im Rahmen dieses Frameworks gewählt werden sollte.

Da der Fahrer seine volle Leistungsfähigkeit bezüglich der Fahraufgabe nur sukzessive erreicht, müssen die Defizite durch die Automation ausgeglichen werden. Infolgedessen soll eine kooperative Transitionsphase realisiert werden, in der beide Kooperationspartner (Mensch und Automation) ein Drehmoment auf das Lenkrad ausüben und damit das Fahrzeug steuern. Um die Automation in diesem Szenario entwerfen zu können, ist eine Beschreibung erforderlich, welche es ermöglicht diese wechselseitige Bedienung zu modellieren. Darüber hinaus sollte es möglich sein, den jeweiligen

Einfluss des Partners auf die Regelungsaufgabe abzubilden, also wie stark ein Partner in die Steuerung des Fahrzeugs involviert ist. Durch eine Verschiebung dieser Steuerungskompetenz kann dann eine Übergabe der Fahraufgabe zwischen der Automation und dem menschlichen Fahrer erfolgen. Nachdem eine Modellierungsform mit den genannten Eigenschaften vorliegt, kann letztlich die Frage adressiert werden, wie die spezifischen Verläufe der Übergaben, also der Verschiebungen der Steuerungskompetenz, gewählt und an den Menschen angepasst werden können, damit dieser optimal unterstützt wird.

Die Vorstellung des im Rahmen von PAKoS entwickelten Systems für die kooperative Transition der Fahraufgabe erfolgt, indem diese beiden Fragen nacheinander beantwortet werden. Nachdem im nachfolgenden Abschnitt die genutzte Modellierungsform eingeführt wird, erläutert Abschnitt 2.1.2.2. die Verwendung des Modells zur Gestaltung der Transition. Die Validierung des neuen Transitionskonzepts ist Gegenstand von Abschnitt 2.1.2.3. und das Unterkapitel schließt mit einer Zusammenfassung der Ergebnisse in Abschnitt 2.1.2.4.

#### *2.1.2.1. Modellierung der Mensch-Maschine-Interaktion*

Bevor die genutzte Modellform im Detail erläutert wird, soll die Grundidee des Haptic Shared Control vorgestellt werden, das als Designparadigma für die kooperative Übergangsphase dient. Abbink und Mulder definieren Haptic Shared Control als Methoden der Mensch-Maschine-Interaktion, die es sowohl dem Menschen, als auch der Automation erlauben Kräfte bzw. Momente auf ein Stellglied auszuüben, über welches das System gesteuert wird [Abbink.2010]. Ein Literaturüberblick über vielfältige Anwendungen von Haptic Shared Control in der Steuerung von Robotern und Fahrzeugen ist in [Abbink.2012] gegeben. Das Konzept ist ein vielversprechender Weg, den Menschen bei der Steuerung eines technischen Systems zu unterstützen. Aufgrund der physischen Verbindung zwischen Mensch und Automation über die gleiche Schnittstelle (d. h. im Falle der Fahrzeugführung das Aufbringen von Drehmoment auf das Lenkrad) ist eine implizite und intuitive Kommunikation zwischen beiden Partnern möglich, da unmittelbares Feedback über die Aktion des jeweils anderen Partners vorliegt.

Mit einer derartigen aktionsbasierten Kooperation ist es möglich auf jegliche Art von expliziten Kommunikationskanälen, wie Displays, zu verzichten und somit die kognitive Arbeitsbelastung des Menschen zu reduzieren. Dies macht das Konzept auch in zeitkritischen Anwendungen nutzbar. Darüber hinaus kann die Automation durch das Feedback des Menschen auf sein Situationsbewusstsein schließen und ihn so beim Aufbau seiner vollen Fahrfähigkeit unterstützen. Durch die gemeinsame Ausführung der Fahraufgabe wird der Mensch langsam an die alleinige Kontrolle des Fahrzeuges durch die Automation herangeführt. Um das ideale Maß der an den

Menschen übergebenen Steuerkompetenz zu bestimmen, wird eine Bewertung der Aktion des Fahrers am Lenkrad vorgenommen. Sie bildet schließlich die Basis für den Adaptionsalgorithmus der Automation, welche sich optimal an den Menschen anpasst.

Die beschriebene Situation der gemeinsamen Steuerung des Fahrzeugs durch den menschlichen Fahrer und die Automation wird durch die Regelungsstruktur in Abb. 15 veranschaulicht. Sie führt darüber hinaus den von uns genutzten Modellierungsansatz ein. Zur Realisierung des kooperativen Fahrens auf Basis des Haptic-Shared-Control-Paradigmas wurde in Übereinstimmung mit mehreren anderen Autoren ein spieltheoretischer Ansatz verwendet [Tamaddoni.2011; Na.2013; Flad.2014; Flad.2018].

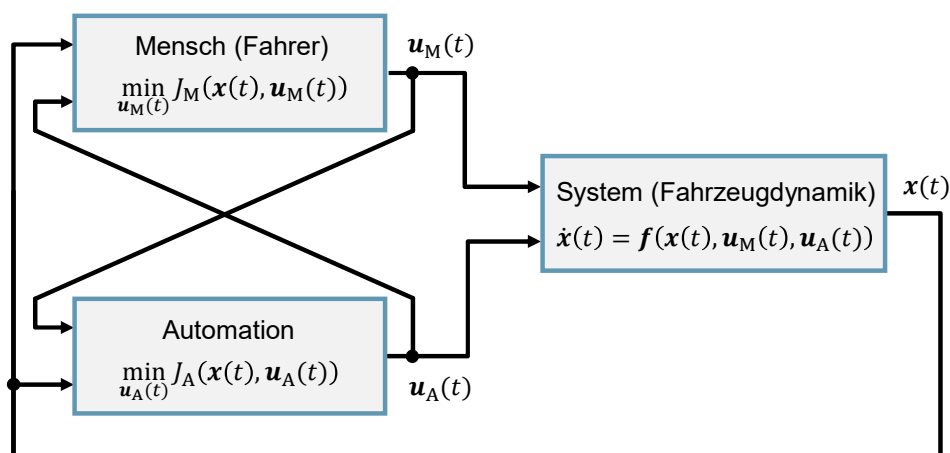


Abbildung 15: Modellierung der Mensch-Maschine-Interaktion mittels eines spieltheoretischen Ansatzes.

Die Interaktion zwischen den beiden Partnern (Fahrer und Automation) sowie dem Fahrzeug wird mittels eines Differentialspiels beschrieben. Die Kooperationspartner werden als Spieler betrachtet, die individuelle Ziele verfolgen. So strebt der menschliche Fahrer das Erreichen seines persönlichen Ziels an, die Fahraufgabe entsprechend eigener Präferenzen und Fähigkeiten zu erfüllen. Mathematisch lässt sich dies mit Hilfe der Zielfunktion  $J_M$  ausdrücken. Im Rahmen der Querführung des Fahrzeugs umfasst  $J_M$  u. a. die Abweichung des Fahrzeugs von der gewünschten Trajektorie sowie den notwendigen Aufwand des Menschen, abgebildet über seine Stellgröße  $\mathbf{u}_M(t)$ . Durch Minimierung dieser Zielfunktion wählt der Fahrer das Steuersignal  $\mathbf{u}_M(t)$  so, dass die Fahraufgabe unter gleichzeitiger Minimierung des Stellaufwandes erfüllt wird. Die Modellierung des Menschen als ein derartiger optimaler Regler bedient sich einer dem Stand der Forschung entstammenden Methode zur Beschreibung menschlicher Bewegungen [Todorov.2002]. Darüber hinaus stellt die Gestaltung einer Automatisierung durch Minimierung einer Zielfunktion einen bekannten Regelungsansatz dar. Folglich kann  $J_A$  auf analoge Weise formuliert und interpretiert werden. Die von der Automation applizierte Stellgröße  $\mathbf{u}_A(t)$  ergibt sich dementsprechend durch die Minimierung von  $J_A$ .

Die beiden Partner interagieren jedoch miteinander und sind über den gleichen Aktor sowie die System- bzw. Fahrzeugdynamik, hier als Differentialgleichung  $\dot{\mathbf{x}}(t) = \mathbf{f}(\mathbf{x}(t), \mathbf{u}_M(t), \mathbf{u}_A(t))$  beschrieben, verkoppelt, d. h. sie wirken beide auf den Systemzustand  $\mathbf{x}(t)$  ein. Daraus resultiert ein verkoppeltes dynamisches Optimierungsproblem, welches als Differentialspiel bezeichnet wird. Die Spieler müssen sich auf ihre Stellgrößen einigen, um ihre Ziele so gut wie möglich zu erfüllen. Normalerweise endet das Spiel in einem stabilen Gleichgewicht, in dem kein Spieler von der gewählten Strategie abweicht. Im Allgemeinen unterscheidet sich diese Gleichgewichtsstrategiekombination von der Kombination, die aufgrund der individuellen Optimierung jedes Spielers entstehen würde, wenn der andere Spieler nicht berücksichtigt wird.

Um Veränderungen im Verhalten der Partner modellieren zu können, wurde der Modellierungsansatz um zeitvariable Gewichtungparameter erweitert. Dies ermöglicht die Gestaltung von Übergängen zwischen dem menschlichen Partner und der Automation. Der Prozess der Transitionsphase beginnt damit, dass die Automatisierung das Fahrzeug vollständig steuert, während der menschliche Partner gerade erst beginnt, die Kontrolle wieder zu erlangen. Mit zunehmendem Situationsbewusstsein steigt auch die Leistungsfähigkeit des Menschen und er wird besser in der Lage sein, die Fahraufgabe selbstständig zu bewältigen. Dies kann in der Zielfunktion  $J_M$  des Fahrers modelliert werden, indem die Gewichtung der Abweichung von der gewünschten Fahrzeugtrajektorie mittels des Transitionsparameters  $\alpha_M(t)$  erhöht wird. Seine Werte reichen von 0 (keine Kontrolle) bis 1 (volle Kontrolle). Analog dazu kann mit dem Transitionsparameter  $\alpha_A(t)$  ebenso die Beteiligung der Automation an der Fahraufgabe angegeben werden.

Fasst man alle oben genannten Punkte zusammen, ergibt sich unter der Annahme von quadratischen Zielfunktionen für den Menschen und die Automation und einer linearen Systemgleichung das folgende Differentialspiel, wobei zur Vereinfachung der Notation die Abhängigkeiten von der Zeit vernachlässigt wurden.

Die Spieler, Mensch und Automation, minimieren jeweils ihre Zielfunktionen

$$J_M = \frac{1}{2}(\mathbf{x}_T - \bar{\mathbf{x}}_T)^T \alpha_{M,T} \mathbf{S}^*(\mathbf{x}_T - \bar{\mathbf{x}}_T) + \frac{1}{2} \int_0^T (\mathbf{x} - \bar{\mathbf{x}})^T \alpha_M \mathbf{Q}^*(\mathbf{x} - \bar{\mathbf{x}}) + \mathbf{u}_M^T \mathbf{R} \mathbf{u}_M dt$$

und

$$J_A = \frac{1}{2}(\mathbf{x}_T - \bar{\mathbf{x}}_T)^T \alpha_{A,T} \mathbf{S}^*(\mathbf{x}_T - \bar{\mathbf{x}}_T) + \frac{1}{2} \int_0^T (\mathbf{x} - \bar{\mathbf{x}})^T \alpha_A \mathbf{Q}^*(\mathbf{x} - \bar{\mathbf{x}}) + \mathbf{u}_A^T \mathbf{R} \mathbf{u}_A dt$$

unter den Nebenbedingungen der Systemdynamik

$$\dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u}_H + \mathbf{B}\mathbf{u}_A$$

und dem Startzustand

$$\mathbf{x}(0) = \mathbf{x}_0.$$

Die Zielfunktionen bestehen aus verschiedenen Komponenten. Einerseits wird die Abweichung der tatsächlichen Systemzustände  $\mathbf{x}$  vom Sollzustand bzw. der Soll-Fahrzeugtrajektorie  $\bar{\mathbf{x}}$  bestraft. Dabei wird sowohl der Verlauf des Zustands über dem betrachteten Zeithorizont  $T$  berücksichtigt, indem die Funktion  $\frac{1}{2}(\mathbf{x} - \bar{\mathbf{x}})^T \alpha_{M/A} \mathbf{Q}^*(\mathbf{x} - \bar{\mathbf{x}})$  von 0 bis  $T$  integriert wird, als auch der Zustand  $\mathbf{x}_T = \mathbf{x}(T)$  am Ende der Optimierung über den Term  $\frac{1}{2}(\mathbf{x}_T - \bar{\mathbf{x}}_T)^T \alpha_{M/A,T} \mathbf{S}^*(\mathbf{x}_T - \bar{\mathbf{x}}_T)$ . Die Matrizen  $\mathbf{Q}^*$  und  $\mathbf{S}^*$  beschreiben hierbei die Gewichtungsmatrizen, mit denen die Abweichungen während einer alleinigen Fahrt ( $\alpha_{M/A} = 1$ ) des jeweiligen Partners bestraft werden. Diese werden, ebenso wie die Referenztrajektorie  $\bar{\mathbf{x}}$ , für den Menschen und die Automation als identisch angenommen. Zusätzlich bestraft jeder Spieler in seiner Zielfunktion auch seinen individuellen Stellgrößenaufwand innerhalb des betrachteten Optimierungszeitraums. Dies erfolgt über den Term  $\frac{1}{2} \mathbf{u}_{M/A}^T \mathbf{R} \mathbf{u}_{M/A}$ , wobei  $\mathbf{R}$  erneut eine für beide Kooperationspartner identische Gewichtungsmatrix darstellt. Die Matrizen  $\mathbf{A}$  und  $\mathbf{B}$  der Systemdifferentialgleichung ergeben sich aus der Linearisierung der Fahrzeugdynamik.

Die Lösung des so formulierten Differentialspiels führt direkt zur optimalen Reaktion der Automation auf den menschlichen Partner für die Phase der kooperativen Transition. Beide Spieler wählen ihre jeweiligen Aktionen so aus, dass ihre individuelle Zielfunktion minimiert wird. Da die Spieler über die Zustandsgleichungen miteinander verbunden sind, beeinflusst die Aktion des einen Spielers die optimale Strategie des anderen Spielers. Die daraus resultierende Menge optimaler Strategien  $(\mathbf{u}_M^*, \mathbf{u}_A^*)$  muss also die Eigenschaft haben, dass keiner der Partner durch die einseitige Wahl einer anderen Strategie eine Verbesserung erreichen kann. Eine derartige Strategiekombination wird als Nash-Gleichgewicht bezeichnet. Die Berechnung eines solchen Nash-Gleichgewichts für das hier präsentierte Differentialspiel und eine erste Übertragung auf die Anwendung des Konzepts für Übergaben der Fahrzeugführung zwischen Mensch und Automation wurde in [Ludwig.2017] vorgestellt.

#### 2.1.2.2. Gestaltung der Transition

Die im vorhergehenden Abschnitt vorgestellte Modellierung wird verwendet, um die Interaktion zwischen beiden Kooperationspartnern (Mensch und Automatisierung) sowie dem Fahrzeug zu beschreiben, indem sie als Spieler eines Differentialspiels betrachtet werden. Die Frage, wie ein

spezifischer Übergang, d. h. der Verlauf des Transitionsparameters  $\alpha_A(t)$ , gestaltet werden sollte, um die Aufgabe ideal zwischen den Partnern zu übertragen bleibt jedoch offen. Für deren Beantwortung soll zunächst definiert werden, was im Rahmen des Projekts PAKoS unter einer idealen Transition verstanden wird.

Formal wird eine ideale Transition als Übergang einer Steuerungsaufgabe zwischen zwei Partnern definiert, wenn dieser Übertragungsprozess die Zustände der Regelstrecke nicht beeinflusst. Dies entspricht der Anforderung, dass sich der gemeinsame Einfluss auf das System während des Übergangs nicht von der Art und Weise unterscheidet, in der ein einzelner Partner die Aufgabe erfüllen würde. Voraussetzung für einen solchen Übergang ist, dass beide Partner in der Lage sind, die Aufgabe allein zu erfüllen. Für das gegebene Problem der Übergabe der Fahraufgabe in einem Fahrzeug mit einer Automation des SAE-Levels 3 (oder Level 4) ist dies erfüllt. Es konnte im Rahmen des Projekts gezeigt werden, dass die Erfüllung der Gleichung

$$\alpha_A(t) + \alpha_M(t) = 1$$

eine Voraussetzung für eine solche ideale Transition ist [Ludwig.2020]. Diese Forderung stellt sicher, dass beide Partner gemeinsam hinreichend stark an der Fahraufgabe beteiligt sind, um während der Übergabe keine Abweichungen von der regulären Fahrzeugführung, d. h. ohne Transition zwischen den Partnern, zu erhalten.

Um die Übergabe der Fahraufgabe, sprich die konkreten Verläufe der Transitionsparameter, zu gestalten, wurden prinzipiell zwei Möglichkeiten entwickelt.

Die erste Option besteht darin, den Übergangsprozess durch einen vordefinierten Verlauf  $\alpha_A(t)$  zu spezifizieren. Aus praktischer Sicht definiert der Verlauf von  $\alpha_A(t)$ , einerseits wie schnell die Automatisierung die Steuerung an den Fahrer delegiert, andererseits den Grad der Unterstützung zu jedem Zeitpunkt der Transitionsphase. Dieser Verlauf kann beispielsweise auf Basis einer Annahme oder aufgrund von Erfahrungswerten über die Art und Weise, wie der menschliche Fahrer seine Fähigkeit zur Fahrzeugführung wiedererlangt (repräsentiert durch den Verlauf von  $\alpha_M(t)$ ), festgelegt werden. Die Automation kann dann im Sinne der idealen Transition komplementär dazu ausgelegt werden. Alternativ kann auch ein Wunschtransitionsverlauf dem Menschen vorgegeben werden, um ihn so zu einer entsprechenden Reaktion zu bewegen. Beispielhafte Verläufe für  $\alpha_A(t)$  und  $\alpha_M(t)$  zeigt Abb. 16. Hier wird ein linearer Anstieg der Beteiligung des Fahrers an der Fahrzeugkontrolle ab dem Zeitpunkt des Hands on (Hände am Lenkrad) angenommen. Dies entspricht einer postulierten linearen Zunahme seiner Leistungsfähigkeit. Die Automation gibt die Steuerungskompetenz lediglich komplementär dazu ab und erzeugt so die notwendige Unterstützung. Wie in Abb. 16 dargestellt, wird die physische Fahrbereitschaft (Hands on) zunächst durch eine Aufforderung zur Übernahme der



Fahrzeugkontrolle (Takeover Request (TOR)) hergestellt. Die Realisierung dieser Informationsphase, sprich die schnellstmögliche und optimale Herstellung der physischen Fahrbereitschaft, wurde im Rahmen von PAKoS durch den Projektpartner an der TUM (Lehrstuhl für Ergonomie) adressiert.

Für die Auswahl eines vorgegebenen Verlaufs  $\alpha_A(t)$  können zusätzlich situationspezifische Faktoren, wie die verbleibende Fähigkeit der Automation oder die Kritikalität der Situation, berücksichtigt werden. Weiterhin kann die Innenraumsituation sensorisch erfasst sowie interpretiert werden (vgl. Abschnitt 2.1.1.). Die Übertragung der Fahrzeugkontrolle erfolgt dann schrittweise, sobald der Fahrer notwendige Anforderungen, wie beispielsweise einen Blick in den Außenspiegel, erfüllt. In [Ludwig.2018a] wurde gezeigt, wie ein solches Gesamtkonzept, bestehend aus Fahrerbeobachtung und kooperativer Transitionsphase, realisiert werden kann.

Die Zeitdauer der Übernahme kann an die aktuelle Fahrsituation, an die Aktionen des Fahrers vor der Übernahmeaufforderung oder an gelernte Erfahrungswerte angepasst werden. In Zusammenhang mit der ersten entwickelten Option zur Gestaltung der Transition werden jedoch alle Parameter für den kooperativen Transitionsprozess im Voraus eingestellt. Es findet keine Online-Anpassung statt.




Abbildung 16: Modellierung der Übertragung der Fahrzeugsteuerung mit Hilfe der Transitionsparameter  $\alpha_M$  und  $\alpha_A$ . Der Parameter der Automation ergibt sich aus der Bedingung für eine ideale Transition unter der angenommenen linearen Zunahme des Transitionsparameters des Menschen.

Bei der zweiten Möglichkeit zur Umsetzung der kooperativen Transitionsphase werden die Rollen vertauscht. In diesem Fall gibt der Mensch den Transitionsverlauf vor, d. h. der Verlauf von  $\alpha_M(t)$  dient als Ausgangspunkt. Die Automation muss, mittels eines Adaptionalgorithmus, online die mentale Bereitschaft des Menschen, sprich den Verlauf von  $\alpha_M(t)$ , erkennen können, um anschließend den eigenen Transitionsparameter so zu wählen, dass eine ideale Transition gemäß

$$\alpha_A(t) = 1 - \alpha_M(t)$$

entsteht. Hierfür wird der Transitionsparameter  $\alpha_M(t)$  auf Grundlage der aktuellen Stellgröße des Fahrers geschätzt und so die aktuelle Leistungsfähigkeit des Menschen in Bezug auf die Übernahme der Fahrzeugführung ermittelt.



Dieses Identifikationsverfahren basiert auf den aktuellen Aktionen des Fahrers  $\mathbf{u}_M(t_0)$  und der Aktion, die gemäß der aktuellen Parametrierung des Modells als optimale Aktion des Menschen aus dem Differentialspiel folgt. Der Fehler des aktuell verwendeten Modells wird über die folgende quadratische Fehlerfunktion berechnet:

$$E(\alpha_M) = \frac{1}{2} (\mathbf{u}_M(t_0) - \mathbf{u}_M^*(\alpha_M, t_0))^T (\mathbf{u}_M(t_0) - \mathbf{u}_M^*(\alpha_M, t_0)).$$

Um den Transitionsparameter zu finden, für den diese Fehlerfunktion minimal wird, d. h. das Modell möglichst gut mit der tatsächlichen Reaktion übereinstimmt, wird das Newton-Verfahren genutzt. Dies führt zu einer iterativen Verbesserung der Schätzung von  $\alpha_M$ . Der Schätzwert zum nächsten Iterationsschritt  $n + 1$  ergibt sich aus den Werten im aktuellen Schritt  $n$  gemäß der Update-Vorschrift des Newton Verfahrens

$$\alpha_{M,n+1} = \alpha_{M,n} - E''(\alpha_{M,n})^{-1} E'(\alpha_{M,n}).$$

$E'(\alpha_{M,n})$  und  $E''(\alpha_{M,n})$  bezeichnen hierbei die erste und zweite Ableitung der quadratischen Fehlerfunktion in Bezug auf  $\alpha_M$ . Aus der Schätzung, der Formel für eine ideale Transition und der Lösung des Differentialspiels wird schließlich die optimale Reaktion der Automatisierung auf den menschlichen Fahrer berechnet. Details zum Schätzverfahren, insbesondere zur Berechnung der Ableitungen  $E'(\alpha_{M,n})$  und  $E''(\alpha_{M,n})$ , finden sich in [Ludwig.2020].

### 2.1.2.3. Validierung des Transitionskonzepts

Um den praktischen Nutzen einer mit den Verfahren aus den vorangegangenen Abschnitten umgesetzten, kooperativen Transitionsphase zu untersuchen, muss das Konzept im Zusammenspiel mit dem Menschen validiert werden.


Mit Hilfe eines Vorversuchs konnte die Umsetzbarkeit des Ansatzes gezeigt werden. Hierfür wurde am IRS eine abstrahierte Fahraufgabe in einem Experiment umgesetzt, in dem die Probanden mit Hilfe eines Lenkrads mit einem Punkt einer Linie folgen sollten. Anhand dieser Aufgabe wurde das oben beschriebene, auf zeitvarianten Differentialspielen basierende, Transitionskonzept mit alternativen Übergabekonzepten aus dem aktuellen Stand der Technik verglichen. Sowohl hinsichtlich der objektiven Versuchsergebnisse, als auch hinsichtlich der Bewertung durch die Probanden wies das neue Transitionskonzept die besten Werte auf. Weitere Details und die exakten Resultate zu diesem Vorversuch sind in [Ludwig.2018b] zu finden.

Nach den vielversprechenden Ergebnissen des Vorversuchs wurde das Konzept auf das im Projekt zentrale Thema der Übernahme der Fahraufgabe nach Aufforderung durch das Automationssystem

übertragen. Aus Sicherheitsgründen wurde das Szenario mit Hilfe eines Fahrsimulators untersucht. Im ersten Experiment wurde das kooperative Transitionskonzept mit einer direkten, also abrupten, Übergabe der Fahraufgabe an den Fahrer verglichen. Die kooperative Transition wurde über eine a priori definierte lineare Abnahme von  $\alpha_A(t)$  nach dem Hands on realisiert. Das zweite Experiment stellt die beiden Gestaltungsmöglichkeiten für den Transitionsverlauf aus Abschnitt 2.1.2.2. gegenüber, um potenzielle Unterschiede zwischen der definierten Vorgabe des Transitionsverlaufs und der Online-Anpassung aufzuzeigen. Im nachfolgenden Abschnitt werden zunächst der verwendete Fahrsimulator und das TestszENARIO beschrieben, was für beide Experimente identisch war. Anschließend werden nacheinander die Ergebnisse der beiden Fahrsimulatorstudien vorgestellt.

### Versuchsdesign

Beide Studien wurden mit dem Fahrsimulator des Lehrstuhls für Ergonomie an der TUM durchgeführt. Der statische Fahrsimulator verwendet sechs Projektoren. Drei Projektoren bilden die Frontsicht und erzeugen so ein Sichtfeld von ca. 180° auf der Hauptleinwand. Die übrigen Projektoren erzeugen jeweils auf drei getrennten Leinwänden die Sicht nach hinten, die vom Fahrersitz über die beiden Seiten- und den Innenspiegel eingesehen werden kann. Die Berechnung der Fahrzeugdynamik, der Visualisierung, des 3D-Sounds und der Datenverarbeitung erfolgt mit der Fahrsimulationssoftware SILAB Version 5.0. Das Lenkrad ist an den Elektromotor SENSO-Wheel SD-LC (SENSODRIVE) gekoppelt, um sowohl ein realistisches Lenkgefühl zu erzeugen, als auch die Lenkmomente der Automation bereitzustellen.



*Abbildung 17: Umgebungssituation zum Zeitpunkt der Übernahmeaufforderung. Ein Pannenfahrzeug steht 200 m entfernt auf der mittleren Spur. Die rechte Spur ist in diesem Fall durch LKWs blockiert.*

Als Teststrecke diente für beide Experimente die Nachbildung einer ca. 17 km langen dreispurigen deutschen Autobahn. Die Probanden sollten, wenn möglich, die hochautomatisierte Fahrfunktion nutzen und während dieser Zeit auf einem Tablet den Surrogate Reference Task [ISO.2012] absolvieren. Hierdurch wurde sichergestellt, dass das Nutzungsverhalten dem einer realen hochautomatisierten Fahrt entspricht und die Versuchspersonen zum Zeitpunkt der Übernahmeaufforderung mental von der Fahraufgabe entkoppelt sind. Kurz vor Ende der Fahrt fand das hier untersuchte Übernahmeszenario statt. Auslöser der Übernahmeaufforderung war ein auf der mittleren Spur lieengebliebenes Fahrzeug. Das automatisierte Fahrzeug befand sich zum Zeitpunkt der Übernahmeaufforderung 200 m vom Pannenfahrzeug entfernt und ebenfalls auf der Mittelspur. Durch die aktuelle Geschwindigkeit von 120 km/h ergibt sich eine Zeitdauer bis zur Kollision von sechs Sekunden, falls der aktuelle Kurs und die Geschwindigkeit beibehalten werden. Da die rechte Fahrspur in dieser Situation blockiert war, musste dem Hindernis auf der linken Seite ausgewichen werden. Abb. 17 illustriert die Situation zum Zeitpunkt der Übernahmeaufforderung in der Simulationssoftware. Die Längsregelung wird bei allen Konzepten zum Zeitpunkt der Übernahmeaufforderung deaktiviert, sodass das Fahrzeug ausrollt bis die Probanden über die Fahrpedale bremsen bzw. beschleunigen. Für die Übergabe der Querregelung wurden drei Konzepte umgesetzt:

1. Direktes Abschalten der Automation
2. Kooperative Transitionsphase mit zeitbasiertem Transitionsverlauf
3. Kooperative Transitionsphase mit adaptiertem Transitionsverlauf

Im ersten Experiment wurden die Konzepte 1 und 2 miteinander verglichen. Für die Variante mit dem direkten Abschalten wurde die Querführungsregelung zeitgleich mit der Längsregelung deaktiviert und die Probanden mussten die kritische Fahrsituation vollständig ohne Unterstützung auflösen. In der zweiten Variante wird angenommen, dass die Fahrfähigkeit des Menschen, wie in Abb. 16 gezeigt, ab dem Zeitpunkt, ab dem die Hände am Lenkrad erkannt werden, linear ansteigt. Aus diesem Grund wurde die Automation so parametrisiert, dass der Transitionsparameter komplementär dazu abnimmt, sodass sich eine kooperative Transitionsphase mit idealer Transition ergibt. Damit die Automation den Fahrer bei der Durchführung des Ausweichmanövers unterstützt, wechselte die Solltrajektorie, ebenfalls zum Zeitpunkt des Hands on, auf einen entsprechenden Spurwechselverlauf.

Im zweiten Experiment erfolgte der Vergleich der Konzepte 2 und 3. Die Umsetzung des zeitbasierten Transitionsverlaufs erfolgte, wie zuvor beschrieben, während für das dritte Übergabekonzept das Identifikationsverfahren aus Abschnitt 2.1.2.2. genutzt wurde. Damit wird online der aktuelle Transitionsparameter des Probanden geschätzt und der Transitionsparameter der Automation zur Laufzeit entsprechend adaptiert.

Die Probanden absolvierten jeweils einen Durchgang mit jedem Konzept. Die Reihenfolge wurde randomisiert und die Darstellung der Situation geringfügig variiert, um Lerneffekten zu vermeiden.

### Ergebnisse des Vergleichs von direkter und kooperativer Transition

Für den Vergleich des kooperativen Transitionskonzepts mit der direkten Übergabe nach dem aktuellen Stand der Technik wurden die aufgezeichneten Datensätze von 31 Personen verwendet (13 weiblich, 18 männlich, Alter 18-62 Jahre, Mittelwert 32,90 Jahre, Standardabweichung 11,93 Jahre).

Abb. 18 zeigt die Fahrzeugschwerpunktrajektorien der 31 Probanden bei sofortiger Übergabe der Fahrzeugführung mit der Übernahmeaufforderung. Die Trajektorien weisen eine breite Streuung auf.




Abbildung 18: Fahrzeugschwerpunktrajektorien aller Probanden des ersten Experiments für die Versuchsdurchgänge mit der direkten Abschaltung der Automation.

Viele Teilnehmer haben Schwierigkeiten, einen reibungslosen Spurwechsel durchzuführen und benötigen viele korrigierende Eingriffe, um das Fahrzeug auf der linken Spur zu stabilisieren. Auf diese Weise kommen einige Fahrer dem Hindernis oder der Leitplanke gefährlich nahe. Im Gegensatz dazu führt das neue Übergabekonzept, d. h. die Gestaltung einer kooperativen Transitionsphase durch Vorgabe eines linearen Transitionsparameterverlaufs zu deutlich besseren Ergebnissen. Dies lässt sich




Abbildung 19: Fahrzeugschwerpunktrajektorien aller Probanden des ersten Experiments für die Versuchsdurchgänge mit kooperativer Transitionsphase und zeitbasiertem Transitionsverlauf.

direkt aus der Betrachtung der Fahrzeugtrajektorien in Abb. 19 ableiten. Die Trajektorien sind fokussierter als im vorherigen Fall und die Fahrer bleiben nahe der Mitte der linken Fahrspur.

Um die beiden Methoden auch quantitativ zu vergleichen, wurden vier Kenngrößen gewählt, anhand derer das Risiko einer Kollision und der fahrdynamische Zustand des Fahrzeugs während des Ausweichmanövers bewertet werden. Die erste Kenngröße bildet die minimale Zeitlücke  $K_t$  bis zur Kollision. Sie beschreibt, wie stark sich die Kritikalität der Situation verschärft bis das Ausweichmanöver eingeleitet wird. Da auch im weiteren Verlauf des Manövers noch die Möglichkeit zur Kollision mit der Leitplanke bzw. der Seite des Hindernisses besteht, wird die zweite Kenngröße  $K_d$  eingeführt, welche den kleinsten seitlichen Abstand zu diesen potenziellen Kollisionsobjekten angibt. Zudem wird der Platzbedarf auf der linken Fahrspur ermittelt. Die Distanz zwischen den Punkten, bei




Abbildung 20: Statistischer Vergleich der minimalen Zeitlücke  $K_t$  zur Kollision für die beiden Versuchskonzepte.




Abbildung 21: Statistischer Vergleich des minimalen lateralen Abstands  $K_d$  zu anderen Objekten für die beiden Versuchskonzepte.




Abbildung 22: Statistischer Vergleich des Platzbedarfs auf der Ausweichspur  $K_D$  für die beiden Versuchskonzepte.

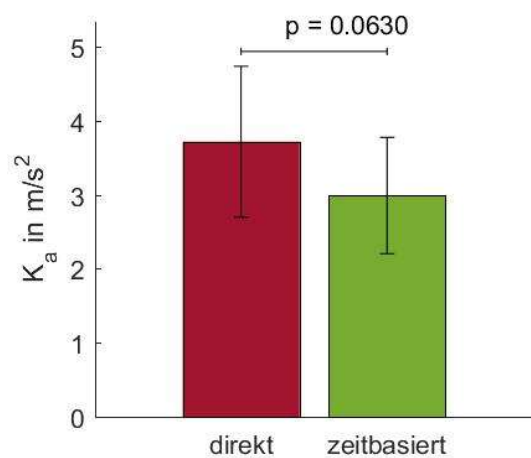


Abbildung 23: Statistischer Vergleich der maximal auftretenden Querbeschleunigung  $K_a$  für die beiden Versuchskonzepte.

denen das Fahrzeug den geringsten Abstand zur Leitplanke bzw. zum Pannenfahrzeug besitzt, wird über die Kennzahl  $K_D$  angegeben. Die vierte und letzte Kennzahl ist die im Verlauf des Manövers maximal auftretende Querbewegung  $K_a$ . Das Ziel für den Übergabeprozess sind hohe Werte für  $K_t$  und  $K_a$ , da diese mit einer geringeren Kritikalität des Spurwechsels korrespondieren und somit die Sicherheit verbessern. Analoges gilt für niedrige Werte von  $K_D$  und  $K_a$ .

Für jede dieser Kenngrößen wurde mit einem Zweistichproben-t-Test für abhängige Stichproben die Nullhypothese überprüft, dass die Werte im Fall einer direkten Abschaltung besser sind, d. h.  $K_t$  und  $K_a$  sind größer und  $K_D$  und  $K_a$  sind kleiner als bei der kooperativen Transition mit dem zeitbasierten Verlauf. Die Mittelwerte der Kenngrößen sowie die p-Werte dieser Tests sind in den folgenden Abb. 20, 21, 22 und 23 dargestellt. Die t-Tests zeigen, dass die Nullhypothesen für alle Kennzahlen bis auf eine ( $K_a$ ) mit einem Signifikanzniveau von 5% abgelehnt werden können. Daher kann davon ausgegangen werden, dass die kooperative Transitionsmethode sowohl die Zeit bis zur Kollision, als auch den Abstand zu anderen Objekten für das gegebene Ausweichmanöver erhöht. Einzig für die Querbewegung kann kein statistisch signifikanter Unterschied festgestellt werden.

Die kooperative Transition verbessert das Fahrverhalten, indem sie den individuellen Mangel an Situationsbewusstsein im gegebenen Szenario durch die Anwendung eines Drehmoments am Lenkrad kompensiert. Dies wird im Folgenden an zwei Beispielpersonen verdeutlicht, welche sehr unterschiedlich auf die Übernahmeaufforderung reagieren. Der erste Fahrer reagiert auf die Übernahmeanforderung mit einem schnellen Ausweichmanöver auf die linke Fahrspur. Ohne Unterstützung hat er jedoch im Weiteren Schwierigkeiten, das Fahrzeug auf der linken Spur zu stabilisieren und kommt sowohl der Leitplanke als auch dem Hindernis gefährlich nahe (rote Trajektorie in Abb. 24). Auch im anderen Versuchsdurchgang führt der Proband eine starke Lenkbewegung durch, um dem Pannenfahrzeug auszuweichen. Durch die neue Methode wird das Ausweichmanöver jedoch mit Hilfe eines Gegenmoments abgemildert, was zu einem deutlich sanfteren Spurwechsel führt (grüne Trajektorie in Abb. 24).

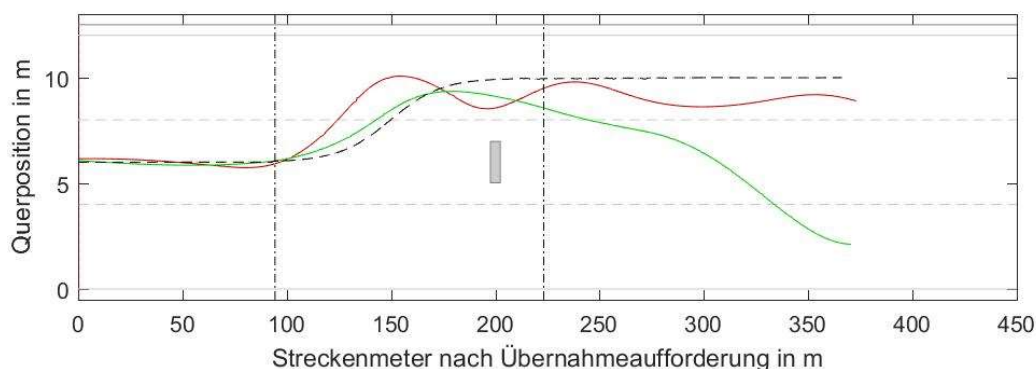


Abbildung 24: Vergleich der Fahrzeugschwerpunkttrajektorien für die direkte Transition (rot) und die zeitbasierte kooperative Transition (grün) für die erste Beispielperson.



Die zweite Beispielperson zeigt die genau entgegengesetzte Reaktion. Anstatt schnell bzw. überambitioniert zu handeln, nimmt sie sich deutlich mehr Zeit, um zu entscheiden und zu reagieren. Im Durchgang, in dem der Proband die Situation allein auflösen musste, fuhr er daher weiter auf das Hindernis zu. Erst spät weicht er dem Hindernis aus und überquert dabei die Mitte der linken Fahrspur (rote Trajektorie in Abb. 25). Im Fall einer kooperativen Transitionsphase unterstützt das System die Entscheidungsfindung, indem es ein Drehmoment in Ausweichrichtung am Lenkrad aufbringt. Auf diese Weise wird der Fahrer zu einer entsprechenden Aktion animiert und führt das Manöver früher und weniger aggressiv aus (grüne Trajektorie in Abb. 25). Das bei Anwendung der kooperativen Transitionphase von der Automation aufgebrachte Lenkmoment ist in Abb. 26 für beide Beispielpersonen dargestellt.

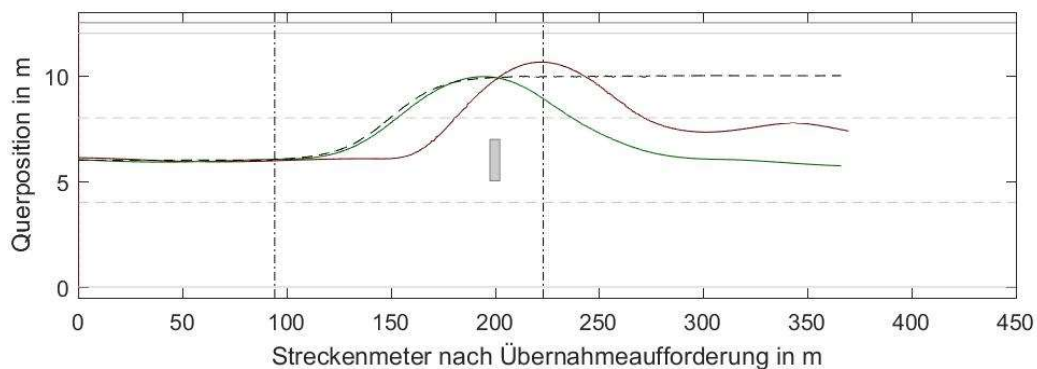


Abbildung 25: Vergleich der Fahrzeugschwerpunkttrajektorien für die direkte Transition (rot) und die zeitbasierte kooperative Transition (grün) für die zweite Beispielperson.

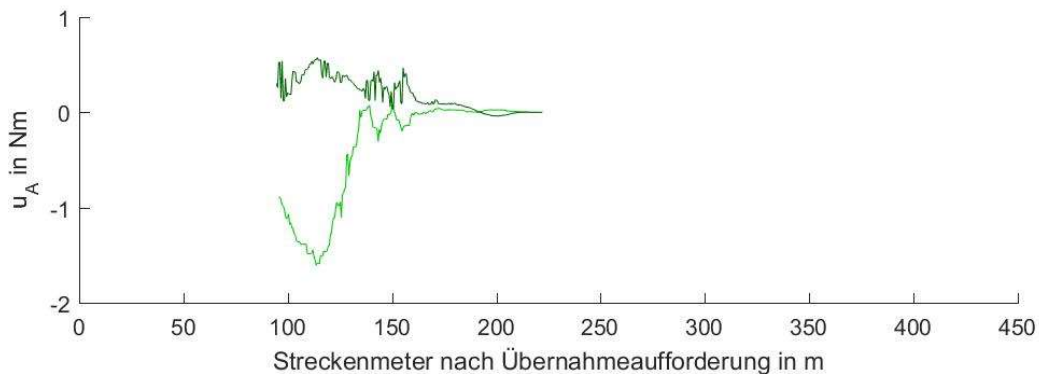


Abbildung 26: Lenkmoment der Automation während der kooperativen Transitionsphase für die beiden Beispielpersonen.

Insgesamt zeigen die Resultate, dass das neuartige Übergabeverfahren basierend auf einer kooperativen Transitionsphase in der Lage ist, das Kollisionsrisiko zu reduzieren und die Fahrzeugstabilität gegenüber dem Stand der Technik (direktes Abschalten der Automation) zu erhöhen.

## Ergebnisse des Vergleichs von vorgegebenem und adaptivem Transitionsverlauf

Nachdem das kooperative Transitionskonzept bei einem a priori vorgegebenen Transitionsverlauf sehr gute Ergebnisse zeigte, wurde in einer weiteren Fahrsimulatorstudie untersucht, ob die Adaption des Transitionsverlaufs auf Basis des online identifizierten Parameterverlaufs des Menschen weitere Verbesserungen erzielt. Die Datenbasis für diesen Vergleich beträgt 31 Personen (6 weiblich, 25 männlich, Alter 19-52 Jahre, Mittelwert 24,88 Jahre, Standardabweichung 7,65 Jahre).

Die Trajektorien für die kooperative Transition mit zeitbasiertem, sprich vorgegebenem, Verlauf sind in Abb. 27 für alle Probanden zu sehen. Die Ergebnisse sind vergleichbar mit den Trajektorien der identischen Transitionsrealisierung aus dem vorangegangenen Experiment (vgl. Abb. 19). Die Trajektorien aller Probanden für den Versuchsdurchgang mit adaptivem Transitionsverlauf zeigt Abb. 28. Sie veranschaulichen, dass die Versuchspersonen auch für diese Wahl des Transitionsparameters den Spurwechsel sicher durchführen können und sich nur geringfügige qualitative Unterschiede zur zeitbasierten Transition ergeben.

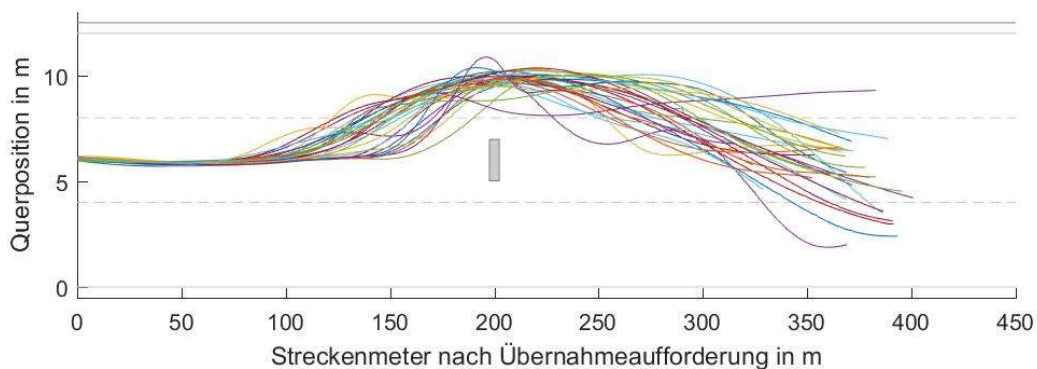


Abbildung 27: Fahrzeugschwerpunkttrajektorien aller Probanden des zweiten Experiments für die Versuchsdurchgänge mit kooperativer Transitionsphase und zeitbasiertem Transitionsverlauf.




Abbildung 28: Fahrzeugschwerpunkttrajektorien aller Probanden des zweiten Experiments für die Versuchsdurchgänge mit kooperativer Transitionsphase und adaptivem Transitionsverlauf.



Dies bestätigen auch die durchgeführten statistischen Tests. Die t-Tests zum Vergleich beider Methoden hinsichtlich derselben Kriterien wie zuvor zeigen, dass es keine statistisch signifikante Verbesserung durch die Verwendung der adaptiven Methode gibt. Die Mittelwerte der Kriterien sowie der p-Wert des Tests sind für die jeweiligen Kenngrößen in den Abb. 29, 30, 31 und 32 dargestellt.

Die experimentellen Ergebnisse zeigen jedoch, dass die adaptive Übergangsmethode dazu beiträgt, den Abstand zur vordefinierten Zieltrajektorie der Automation zu verringern. Da die Automation die Kontrolle nur dann abgibt, wenn der Fahrer diesem Ziel folgt, wird der Fahrer stärker auf dieses Ziel hingeführt, als wenn die Übergabe rein zeitbasiert durchgeführt wird. Folglich wird mit der adaptiven Methode der mittlere Abstand  $K_y$  zur Zieltrajektorie mit statistischer Signifikanz reduziert (vgl. Abb. 33).




Abbildung 29: Statistischer Vergleich der minimalen Zeitlücke  $K_t$  zur Kollision für die beiden Versuchskonzepte.

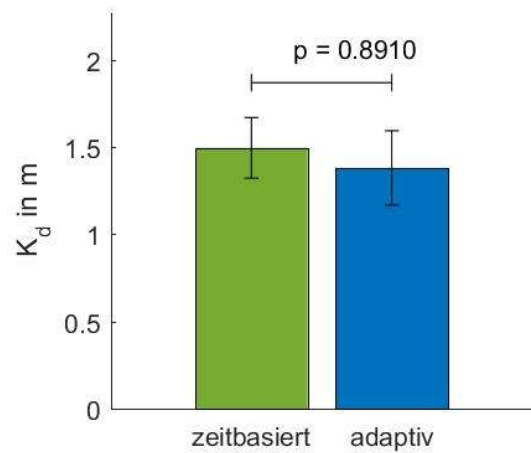


Abbildung 30: Statistischer Vergleich des minimalen lateralen Abstands  $K_d$  zu anderen Objekten der beiden Versuchskonzepte.




Abbildung 31: Statistischer Vergleich des Platzbedarfs auf der Ausweichspur  $K_D$  für die beiden Versuchskonzepte.

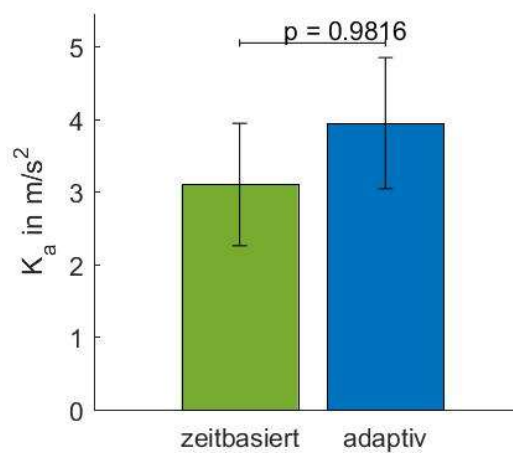


Abbildung 32: Statistischer Vergleich der maximal auftretenden Querbeschleunigung  $K_a$  für die beiden Versuchskonzepte.




Abbildung 33: Statistischer Vergleich des mittleren lateralen Abstands  $K_y$  zur Referenztrajektorie für die beiden Versuchskonzepte.

Insgesamt zeigt der Vergleich der rein zeitbasierten Transition und der adaptiven Variante anhand einer aktionsbasierten Schätzung des Übergabeparameters, dass in der durchgeführten Studie nur ein geringer Unterschied zwischen den Konzepten festgestellt werden kann. In beiden Fällen werden die Probanden jedoch bei der sicheren Durchführung der Übernahme der Fahrzeugführung unterstützt und können das folgende Ausweichmanöver durchführen, ohne dass kritische Situationen auftreten. Letztlich kann mit der adaptiven Variante des Transitionskonzepts einer vorgegebenen Manövertrajektorie besser gefolgt werden.

#### 2.1.2.4. Zusammenfassung

Der im vergangenen Abschnitt 2.1.2. betrachtete Teilaspekt des Projekts PAKoS befasst sich mit der Frage, wie ein Transfer der Fahraufgabe zwischen Mensch und Automation gestaltet werden sollte, um die Qualität der Ausführung und die Sicherheit der Verkehrsteilnehmer während des gesamten Übergabeprozesses zu gewährleisten. Entgegen wissenschaftlicher Erkenntnisse erfolgen bisherige technische Umsetzungen der Transition häufig unter der Annahme, der Mensch könne die Fahraufgabe sofort vollständig übernehmen, infolgedessen die Automation abrupt abgeschaltet wird. Die Annahme ist jedoch insbesondere dann inkorrekt, wenn der Mensch unerwartet zur Übernahme aufgefordert wird und er die aktuelle Situation erst erfassen sowie verarbeiten muss.

Um den Menschen in diesen Fällen zu unterstützen, wird eine kooperative Transition basierend auf dem Konzept des Haptic Shared Control vorgeschlagen. In einer kooperativen Transitionsphase, in der Mensch und Automation gemeinsam mit dem System interagieren und über Momente am Lenkrad wechselseitig kommunizieren, wird die Fahrzeugkontrolle von der Automation nur sukzessive an den

Menschen übergeben. Der Fahrer wird somit unterstützt bis er seine vollständige mentale Fahrbereitschaft aufgebaut hat. Die methodische Grundlage für die Realisierung dieser Kooperation bildet eine systematische Modellierung der Interaktion zwischen Mensch und Maschine. Mittels der Beschreibung beider Partner als Optimalregler (Differentialspiel) lässt sich der Einfluss des jeweiligen Partners auf die Fahraufgabe durch zeitabhängige Gewichtungparameter (Transitionsparameter) beschreiben. Indem der Verlauf dieses Parameters für die Automation geeignet gestaltet wird, kann der Regler, welcher aus der Lösung des Differentialspiels folgt, den Menschen optimal unterstützen. Im Rahmen von PAKoS wurden zwei Varianten entwickelt, um den Transitionsparameter für die Automation zu bestimmen und damit den Übergabeprozess zu realisieren. Im ersten Fall wird der Transitionsverlauf a priori auf Basis von Vorwissen vorgegeben und der entsprechende Parameter im Betrieb zeitbasiert ausgewählt. In der zweiten Variante erfolgt die Bestimmung zur Laufzeit, auf Basis einer Schätzung der aktuellen Übernahmebereitschaft des Menschen.

Die kooperativen Übergabemethoden wurden in zwei Fahrsimulatorstudien validiert. Das grundlegende Fahrscenario bildete in beiden Fällen ein Ausweichmanöver. Das erste Experiment vergleicht ein direktes Abschalten der Automation mit einer kooperativen Transitionsphase und vorgegebenem Transitionsverlauf. Die Ergebnisse zeigen, dass unter Nutzung des neuen Konzepts die Ausweichmanöver sicherer erfolgen. Durch die Unterstützung sind die Fahrer in der Lage, größere Abstände und Zeitlücken zu anderen Objekten einzuhalten und das Fahrzeug mit weniger Querbewegung auf der Zielspur zu stabilisieren. Über die haptischen Signale während der kooperativen Transition werden sowohl Fahrer zum Ausweichmanöver animiert, falls sie verspätet reagieren, als auch hektische Überreaktionen durch entsprechende Gegenmomente abgemildert. Im Rahmen einer zweiten Probandenstudie wurden die beiden Varianten zur Bestimmung des Transitionsverlaufs miteinander verglichen. Neben der sicheren Handhabung der Situation, zeigen die Ergebnisse, dass die Fahrer durch das adaptive Verfahren stärker in Richtung der Referenzvorgabe der Automation geführt werden.

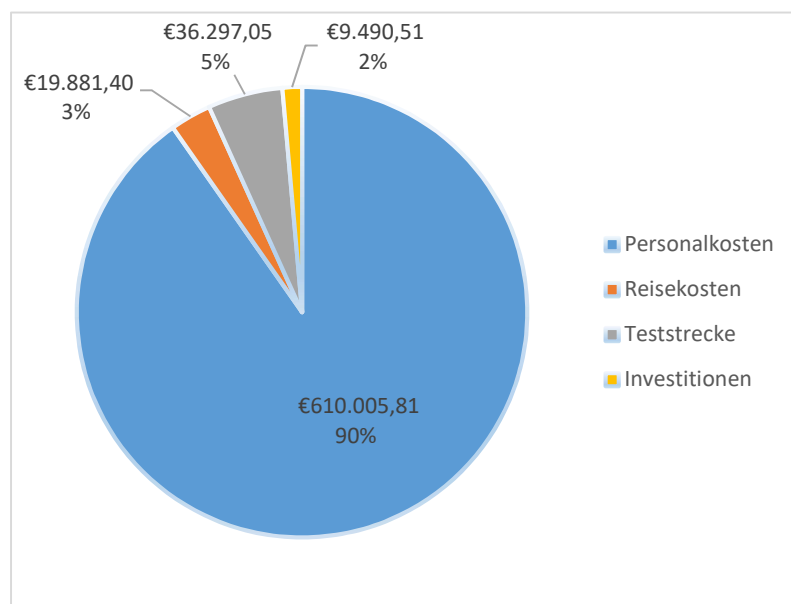
Insgesamt machen die Ergebnisse der Fahrsimulatorstudien deutlich, dass eine direkte Übergabe der Fahraufgabe von der Automation an den Menschen, wie beim heutigen Stand der Technik, nicht sinnvoll ist. Vielmehr bietet das vorgestellte Konzept einer kooperativen Transition auf Basis der Modellierung der Mensch-Maschine-Interaktion mit einem Differentialspiel einen Weg, diesen Übergang für den menschlichen Partner sicherer, komfortabler und intuitiver zu gestalten.

## 2.2. Wichtigste Positionen des zahlenmäßigen Nachweises

Da der Fokus des KIT in der Entwicklung der Konzepte und theoretischen Lösungen lag, bilden die Personalkosten den wesentlichen Kostenpunkt. Dazu kommen in geringerem Maße noch die Material- und Investitionskosten für die Durchführung von Vorstudien sowie die Hardware zur Umsetzung der Algorithmen. Darüber hinaus waren Finanzaufwendungen für Reisen (nationale und internationale Fachkonferenzen, Netzwerktreffen, Workshops, etc.) und die Miete der Teststrecke für die Realfahrtstudien nötig. Die Projektpauschale (20%) ist nachfolgend nicht berücksichtigt.

*Tabelle 4: Tabellarische Finanzübersicht für den KIT-Teil des PAKoS-Projekts.*

Kostenart	Kosten
Personalkosten	610.005,81 €
Vergabe von Verträgen (Miete der Teststrecke)	36.297,05 €
Reisekosten	19.881,40 €
Investitionen/Material	9.490,51 €
<b>Gesamtkosten</b>	<b>675.674,77 €</b>



*Abbildung 34: Finanzübersicht für den KIT-Teil des PAKoS-Projekts.*

## 2.3. Notwendigkeit und Angemessenheit der geleisteten Arbeit

Das Forschungsvorhaben PAKoS konnte aufgrund seiner Komplexität und Interdisziplinarität nur im Rahmen eines Verbundprojektes bearbeitet werden. Auf wissenschaftlicher Ebene wurden in dem Projekt erstmalig Forschungsgebiete zusammengeführt, die üblicherweise sonst losgelöst agieren. Die Integration dieser Wissensdomänen ist erforderlich, um die in dem Projekt adressierten Problemstellungen zu lösen. Es ist davon auszugehen, dass die alleinigen Entwicklungen durch OEM,

Lieferanten und Forschungseinrichtungen eher zu spezifischen Lösungen für den jeweiligen Kundenkreis geführt hätten. Im Gegensatz dazu stehen die in diesem Bericht vorgestellten und die Rahmen von PAKoS entwickelten Lösungskonzepte für die Fahrerbeobachtung und -interpretation sowie die Transition der Fahraufgabe. Diese weisen aufgrund ihrer fundierten theoretischen Methoden eine universelle Anwendbarkeit auf und berücksichtigen darüber hinaus, durch die im Projekt beteiligten Lieferanten und OEMs, Anforderungen, welche sich in der praktischen Umsetzung ergeben. Als Vergleich zu bisherigen Ansätzen aus dem Stand der Technik der Fahrerbeobachtung und Kontrollübergabe sei hier nochmals auf Abschnitt 1.4. verwiesen.

Nur mit Hilfe der Förderung des BMBF bestand die Möglichkeit, die verschiedenen Technologien und Kompetenzen effektiv und effizient in einem Gesamtkonzept zu bündeln. Für das KIT ergab sich mit der Zuwendung die Möglichkeit zusätzliche Personalkapazitäten zu nutzen bzw. Projektmitarbeitern mit dem Fokus auf die adressierten Forschungsaktivitäten, eine Entkopplung vom Tagesgeschäft der Lehre zu ermöglichen. Eine Eigenfinanzierung dieser Forschung wäre als Universität nicht möglich gewesen. Eine EU-Förderung erwies sich als nicht möglich und sinnvoll, da kein alternatives Förderinstrument im Rahmen des Horizon 2020-Programms gefunden wurde. Aus Sicht des KIT sind die entwickelten Lösungen ein wesentliches Schlüsselement für eine sinnvolle und auf den Menschen zentrierte Markteinführung automatisierter Fahrfunktionen.

## 2.4. Nutzen und Verwertbarkeit der Ergebnisse im Sinne des fortgeschriebenen Verwertungsplans

### 2.4.1. Wissenschaftliche Erfolge

Die wissenschaftlichen Projektergebnisse wurden frühzeitig auf entsprechenden Konferenzen veröffentlicht (siehe Veröffentlichungsliste). Folglich trieben sie die innovativen Forschungs- und Entwicklungsarbeiten in den jeweiligen Fachgebieten voran. Das Shared-Control-Konzept, welches für die Übergabe der Fahraufgabe im Projekt entwickelt wurde, wurde in der Fachcommunity und dem entsprechenden IEEE-Arbeitskreis äußerst positiv aufgenommen. Über Deutschland hinaus gibt es hier ein sehr reges Interesse japanischer Wissenschaftler, da diese eine ähnliche Fragestellung untersuchen. Des Weiteren haben die Ergebnisse des Projekts PAKoS Einzug in ein Buch des renommierten Verlags Springer Nature erhalten (siehe Veröffentlichungsliste). In einem Buchkapitel wird das im Rahmen des Gesamtprojekts entwickelte Konzept eines auf den Menschen zentrierten hochautomatisierten Fahrzeuges („human-centered highly automated car“) zusammengefasst und erläutert. Infolgedessen werden die Ergebnisse von PAKoS einem möglichst breiten Publikum unterschiedlichster Disziplinen zugänglich. Auf Basis der Arbeit im Projekt konnte ein, in der

Fragestellung vereinfachter, Workshop für die Vorlesung „Praktischer Entwurf regelungstechnischer Systeme“ abgeleitet werden. Dieser dient seither für die grundlegende und zugleich praxisorientierte Ausbildung junger Ingenieurinnen und Ingenieure, aber auch der Heranführung dieser an die Problematiken des hochautomatisierten Fahrens.

Von besonderem Nutzen für die Forschungsgemeinschaft ist die Erstellung von *Drive&Act* - dem ersten großen Datensatz zur Fahreraktivitätserkennung. Der Datensatz umfasst sowohl manuelle als auch autonome Fahrten und ermöglichte zum ersten Mal das Training tiefer faltender neuronaler Netze für die Erkennung der Fahrernebenaktivität, was früher aufgrund des Datenmangels nur schwer möglich war. Um die Erforschung der Aktivitätserkennung unter realistischen Fahrbedingungen, wie beispielsweise bei geringer Beleuchtung oder eingeschränkter Körpersichtbarkeit, voranzutreiben, wurde der Datensatz nach der Veröffentlichung auf der International Conference on Computer Vision (ICCV, IEEE 2019) der Forschungsgemeinschaft frei zur Verfügung gestellt: [www.driveandact.com](http://www.driveandact.com).

#### 2.4.2. Wirtschaftliche Erfolge

Als Universität strebt das KIT primär keine eigene wirtschaftliche Verwertung an. Nach unserer Einschätzung stellt das von uns entwickelte kooperative Übergabekonzept aber einen essentiellen Baustein für die Einführung des hochautomatisierten Fahrens dar und weist eine klare sowie nachweisbare Verbesserung, in Bezug auf die Verkehrssicherheit, gegenüber dem aktuellen Stand der Technik auf. Es gibt ein entsprechend großes Interesse der Industriepartner des Konsortiums sowie darüber hinaus an diesem Konzept. Ob die Hersteller und Zulieferer für das Konzept überzeugt werden können oder sich doch aus nicht wissenschaftlichen Überlegungen individuelle Lösungen durchsetzen werden, ist zum aktuellen Zeitpunkt noch unklar.

#### 2.4.3. Wissenschaftliche und wirtschaftliche Anschlussfähigkeit

Die Arbeiten am KIT bzgl. der Erforschung haptischer und multimodaler Interaktionskonzepte für kooperative automatisierte Systeme und die daraus resultierende Expertise werden auch zukünftig in anderen nationalen und internationalen Forschungsprojekten der Forschungsgruppe „Kooperative Systeme“ des IRS eingebracht. Als ein erstes Beispiel ist das Projekt HoLLiECares zu nennen, das am 1.2.2020 gestartet ist. In diesem werden die in PAKoS entstandenen Methoden auf die Fragestellung der roboterassistierten Pflege übertragen. Ziel ist es hierbei, ein Kontroll- und Übergabekonzept für einen Roboter zu entwickeln, mit dessen Hilfe dieser Pflegekräfte bei ihrer Tätigkeit unterstützen kann. In Bezug auf die wirtschaftliche Anschlussfähigkeit zeigte sich beim öffentlichen Abschlussevent ein reges Interesse von Firmen aus dem Bereich der Nutzfahrzeuge sowie der land- und



forstwirtschaftlichen Maschinen an den in PAKoS entwickelten Konzepten. Eine Übertragung des kooperativen Interaktions- und Übergabekonzepts auf diese Problemstellung wird aktuell untersucht.

## 2.5. Fortschritte auf dem Gebiet des Vorhabens bei anderen Stellen

Insbesondere in der theoretischen Computer Vision Community wurde in den letzten Jahren eine Vielzahl neuer CNN-basierter Architekturen entwickelt, die vom KIT fortlaufend untersucht, getestet und in den eigens entwickelten Architekturen aufgegriffen wurden. Ein großer Unterschied im Vergleich zu der Situation vor dem Projektbeginn waren die Fortschritte der CNN-Architekturen basierend auf 3D-Faltungen, d. h. sowohl die zeitliche als auch die räumliche Dimension werden verwendet. Diese lösten zunehmend die früheren, bilderbasierten Konzepte, z. B. [Simonyan.2015], ab. Das Inflated 3D ConvNet [Carreira.2017] stellt eine dreidimensionale Version des Google Inception v1-Netzes dar und wurde in PAKoS erfolgreich erprobt.

Im Bereich der Fahrerbeobachtung wurde der neue Datensatz „AUC Distracted Driver“ veröffentlicht [Abouelnaga.2018], bei dem es sich um eine Klassifikation der Fahrerkörperposen handelt. Insgesamt wird zwischen zehn Klassen basierend auf der Körperpose unterschieden (z. B. Telefonieren links und rechts). Während der Datensatz mehr Versuchspersonen als der Drive&Act-Datensatz von PAKoS aufweist (31 vs. 15), beinhaltet *Drive&Act* deutlich mehr Nebentätigkeiten und ist sowohl für die manuelle, als auch die automatisierte Fahrt konzipiert.

Parallel zu PAKoS wurden zwei Ansätze entwickelt, die ebenfalls den Gedanken aufgreifen, die Transition der Fahraufgabe zwischen Fahrer und Automation durch eine Haptic-Shared-Control-Phase zu realisieren. Im Ansatz von Wada et al. wird zunächst für Fahrer und Automation das als Pseudo-Arbeit bezeichnete Produkt zwischen Lenkmoment und Lenkradwinkel gebildet [Wada.2016; Saito.2017; Saito.2018]. Aus dem Vergleich der ermittelten Größen mit vordefinierten Schwellwerten wird anschließend einer von vier möglichen kooperativen Zuständen bestimmt und ggf. eine graduelle Transition eingeleitet. Der Fokus der Arbeiten liegt jedoch auf Übernahme-situationen, bei denen der Mensch diesen Wechsel initiiert und bei vollem Situationsbewusstsein agiert. Die in PAKoS untersuchten kritischen Übergabesituationen bei unaufmerksamen Fahrern werden nicht betrachtet. Im zweiten Ansatz von Lv et al. [Lv.2018] ermittelt die Automationsfunktion die optimale Stellgröße mittels eines modellbasierten Prädiktivreglers und steuert die Differenz zwischen optimalem und vom Fahrer gestelltem Moment vor. Über eine Bereitschaftszustandsbestimmung wird die gewünschte Beteiligung des Fahrers berechnet und ein zusätzlich unterstützendes Moment der Automation appliziert. Für diesen Ansatz fehlen jedoch bisher Ergebnisse, die den Nutzen des Systems durch Studien nachweisen. Aus diesem Grund lässt sich die Qualität der aktuellen

Bereitschaftszustandsbestimmung des Menschen und der darauf angepassten Transition nicht bewerten.

## 2.6. Erfolgte oder geplante Veröffentlichungen der Ergebnisse

Zusätzlich zu den nachfolgend aufgeführten Veröffentlichungen und den obligatorischen Treffen der Förderlinie wurden die Projektergebnisse bei zwei Industriearbeitskreisen der Profilregion Mobilitätssysteme Karlsruhe vorgestellt. Ergänzend dazu fand am 15.11.2019 ein öffentlicher Workshop auf dem Testgelände in Pferdsfeld statt, bei dem, neben der Vorstellung der Lösungskonzepte, das System von den Besuchern auch real erlebt werden konnte. Dieses Event fand sehr großen Zuspruch. Ergänzend dazu wurde in zwei Radiobeiträgen, einem Fernsehbeitrag und verschiedenen Beiträgen in den Printmedien über das PAKoS-Projekt berichtet.

- [Flad.2018] Flad, Michael: “Differential-Game-Based Driver Assistance System for Fuel-Optimal Driving”. In: *Frontiers of Dynamic Games – Game Theory and Management*, Ed.: L. Petrosyan, Birkhäuser, St. Petersburg, 2018.
- [Gebert.2019] Gebert, Patrick\*; Roitberg, Alina\*; Haurilet, Monica; Stiefelhagen, Rainer: “End-to-end Prediction of Driver Intention using 3D Convolutional Neural Networks”. In: *Intelligent Vehicles Symposium (IV)*, IEEE, Paris, 2019. (\*equal contribution)
- [Ludwig.2017] Ludwig, Julian; Gote, Christoph; Flad, Michael; Hohmann, Sören: “Cooperative Dynamic Vehicle Control Allocation using Time-variant Differential Games”. In: *International Conference on Systems, Man, and Cybernetics (SMC)*, IEEE, 2017.
- [Ludwig.2018a] Ludwig, Julian; Martin, Manuel; Horne, Matthias; Flad, Michael; Voit, Michael; Stiefelhagen, Rainer; Hohmann, Sören: “Driver Observation and Shared Vehicle Control Supporting the Driver on the Way back into the Control Loop”. In: *at – Automatisierungstechnik*, 66(2), 2018.
- [Ludwig.2018b] Ludwig, Julian; Haas, Andreas; Flad, Michael; Hohmann, Sören: “A Comparison of Concepts for Control Transitions from Automation to Human”. In: *International Conference on Systems, Man and Cybernetics (SMC)*, IEEE, 2018.
- [Ludwig.2020] Ludwig, Julian: “Automatisierte kooperative Transition einer Regelungsaufgabe zwischen Mensch und Maschine am Beispiel des hochautomatisierten Fahrens”. Dissertation, Fakultät für Elektrotechnik und Informationstechnik des Karlsruher Institut für Technologie, KIT Scientific Publishing, 2020. (Geplant)
- [Martin.2019a] Martin, Manuel; Ludwig, Julian; Roitberg, Alina; Flad, Michael; Voit, Michael; Hohmann, Sören; Stiefelhagen, Rainer: “Innenraumbeobachtung für die kooperative Übergabe zwischen hochautomatisierten Fahrzeugen und Fahrer”. In: *10. VDI-Tagung Mensch-Maschine-Mobilität*, Bd. 10, Braunschweig, 2019.
- [Martin.2019b] Martin, Manuel\*; Roitberg, Alina\*; Haurilet, Monica; Horne, Matthias; Reiß, Simon; Voit, Michael; Stiefelhagen, Rainer: “Drive&Act: A Multi-modal Dataset for Fine-

- grained Driver Behavior Recognition in Autonomous Vehicles”. In: International Conference on Computer Vision (ICCV), IEEE, Seoul, 2019. (\*equal contribution)
- [Reiß.2020a] Reiß, Simon; Roitberg, Alina; Haurilet, Monica; Stiefelhagen, Rainer: “Deep Classification-driven Domain Adaptation for Cross-Modal Driver Behavior Recognition”. In: Intelligent Vehicles Symposium (IV), IEEE, 2020. (under review)
- [Reiß.2020b] Reiß, Simon; Roitberg, Alina; Haurilet, Monica; Stiefelhagen, Rainer: “Activity-aware Attributes for Zero-Shot Recognition in Context of Driver Observation”. In: Intelligent Vehicles Symposium (IV), IEEE, 2020. (under review)
- [Roitberg.2018a] Roitberg, Alina; Al-Halah, Ziad; Stiefelhagen, Rainer: “Informed Democracy: Voting-based Novelty Detection for Action Recognition”. In: British Machine Vision Conference (BMVC), Newcastle, 2018.
- [Roitberg.2018b] Roitberg, Alina; Martinez, Manuel; Haurilet, Monica; Stiefelhagen, Rainer: “Towards a Fair Evaluation of Zero-Shot Action Recognition using External Data”. In: ECCV Workshop on Shortcomings in Vision and Language (SiVL), Springer, Munich, 2018.
- [Roitberg.2019] Roitberg, Alina; Pollert, Tim; Haurilet, Monica; Martin, Manuel; Stiefelhagen, Rainer: “Analysis of Deep Fusion Strategies for Multi-modal Gesture Recognition”. In: CVPR Workshop on Analysis and Modeling of Faces and Gestures (AMFG), IEEE, Long Beach, 2019.
- [Roitberg.2020a] Roitberg, Alina; Haurilet, Monica; Reiß, Simon; Stiefelhagen, Rainer: “CNN-based Driver Activity Understanding - Shedding Light on Deep Spatiotemporal Representations”. In: Intelligent Transportation Systems Conference (ITSC), IEEE, 2020. (under review)
- [Roitberg.2020b] Roitberg, Alina; Ma, Choxiang; Haurilet, Monica; Stiefelhagen, Rainer: “Open Set Driver Activity Recognition”. In: Intelligent Vehicles Symposium (IV), IEEE, 2020. (under review)
- [Schwarz.2017] Schwarz, Anke\*; Haurilet, Monica\*; Martinez, Manuel; Stiefelhagen, Rainer: “DriveAHead - A Large-Scale Driver Head Pose Dataset”. In: Conference on Computer Vision and Pattern Recognition Workshops, IEEE, 2017. (\*equal contribution)

Die Ergebnisse des gesamten Projekts PAKoS bilden zudem den Inhalt eines Buchkapitels in der Human-Computer Interaction Series des Verlags Springer Nature.

- [Flad.2020] Flad, Michael; Karg, Philipp; Roitberg, Alina; Martin, Manuel; Mazewitsch, Marcus; Kenar, Erdi; Ahrens, Lenne; Flecken, Boris; Kalb, Luis; Karakaya, Burak; Ludwig, Julian; Pruksch, Achim; Stiefelhagen, Rainer; Hohmann, Sören: Personalisation and Control Transition between Automation and Driver in Highly Automated Cars. In: Smart Automotive Mobility, Ed.: Gerrit Meixner, Springer, 2020. (under final review, but already listed)

### 3. Literatur

- [Abbink.2006] Abbink, D. A.: “Neuromuscular Analysis of Haptic Gas Pedal Feedback during Car Following”. PhD Thesis, Delft University of Technology, 2006.
- [Abbink.2010] Abbink, D. A.; Mulder, M.: “Neuromuscular Analysis as a Guideline in Designing Shared Control”. In: *Advances in Haptics* (IntechOpen), 2010.
- [Abbink.2012] Abbink, D. A.; Mulder, M.; Boer, E. R.: “Haptic Shared Control: Smoothly Shifting Control Authority?”. In: *Cognition, Technology & Work*, 14(1), 2012.
- [Abouelnaga.2018] Abouelnaga, Y.; Eraqi, H. M.; Moustafa, M. N.: “Real-Time Distracted Driver Posture Classification”. In: *NIPS Workshop on Machine Learning for Intelligent Transportation Systems*, 2018.
- [Baltrušaitis.2016] Baltrušaitis, T.; Robinson, P.; Morency, L. P.: “Openface: An Open Source Facial Behavior Analysis Toolkit”. In: *Winter Conference on Applications of Computer Vision (WACV)*, IEEE, 2016.
- [BLee.2012] Lee, B.-G.; Chung, W.-Y.: “Driver Alertness Monitoring using Fusion of Facial Features and Bio-Signals”. In: *Sensors Journal*, 12(7), IEEE, 2012.
- [Börner.2006] Börner, M.; Isermann, R.: “Model-based Detection of Critical Driving Situations with Fuzzy Logic Decision Making”. In: *Control Engineering Practice*, 14(5), 2006.
- [Carreira.2017] Carreira, J.; Zisserman, A.: “Quo Vadis, Action Recognition? A New Model and the Kinetics Dataset”. In: *Conference on Computer Vision and Pattern Recognition*, IEEE, 2017.
- [Chang.2008] Chang, T.-H.; Hsu, C.-S.; Wang, C.; Yang, L.-K.: “Onboard Measurement and Warning Module for Irregular Vehicle Behavior”. In: *IEEE Transactions on Intelligent Transportation Systems*, 9(3), IEEE, 2008.
- [Damböck.2012] Damböck, D.; Farid, M.; Tonert, L.; Bengler, K.: “Übernahmezeiten beim hochautomatisierten Fahren”. In: *Tagung Fahrerassistenz München*, 2012.
- [Endsley.1995] Endsley, M.; Kiris, E.: “The Out-of-the-Loop Performance Problem and Level of Control in Automation”, In: *Human Factors*, 37(2), 1995.
- [Flad.2014] Flad, M.; Otten, J.; Schwab, S.; Hohmann, S.: “Steering Driver Assistance System: A Systematic Cooperative Shared Control Design Approach”. In: *International Conference on System, Man and Cybernetics (SMC)*, IEEE, 2014.
- [Friedrich.2010] Friedrich, T.; Ziegler, P.: “Verfahren zum Anpassen eines Fahrerassistenzsystems an das Fahrverhalten eines Fahrers”. Patent, Available [Online]: <http://www.google.com/patents/DE102009000296A1?cl=de>.
- [Gold.2013] Gold, C.; Damböck, D.; Lorenz, L.; Bengler, K.: “‘Take Over!’ How Long Does it Take to Get the Driver back into the Loop?”. In: *Hum. Factors Ergon. Soc. Annu. Meet.*, 57(1), 2013.
- [Harris.1996] Harris, C.; An, P.: “An Intelligent Driver Warning System for Vehicle Collision Avoidance”. In: *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, 26(2), IEEE, 1996.

- [ISO.2012] International Organization for Standardization: “Road Vehicles – Ergonomic Aspects of Transport Information and Control Systems – Calibration Tasks for Methods which Assess Driver Demand due to the Use of Invehicle Systems”. ISO/TS 14198:2012(E), 2012.
- [Jain.2015] Jain, A.; Koppula, H. S.; Raghavan, B.; Soh, S.; Saxena, A.: “Car that Knows before You Do: Anticipating Maneuvers via Learning Temporal Driving Models”. In: International Conference on Computer Vision, IEEE, 2015.
- [Jain.2016] Jain, A.; Singh, A.; Koppula, H. S.; Soh, S.; Saxena, A.: “Recurrent Neural Networks for Driver Activity Anticipation via Sensory-Fusion Architecture”. In: International Conference on Robotics and Automation (ICRA), IEEE, 2016.
- [Kawasaki.2004] Kawasaki, N.; Kiencke, U.: “Standard Platform for Sensor Fusion on Advanced Driver Assistance System using Bayesian Network”. In: Intelligent Vehicles Symposium, IEEE, 2004.
- [Lefevre.2015] Lefèvre, S.; Carvalho, A.; Gao, Y.; Tseng, H. E.; Borrelli, F.: “Driver Models for Personalised Driving Assistance”. In: Vehicle System Dynamics, 53(12), 2015.
- [Lv.2018] Lv, C.; Cao, D.; Zhao, Y.; Auger, D.; Sullman, M.; Wang, H.; Dutka, L.; Skrypchuck, L.; Mouzakitis, A.: “Analysis of Autopilot Disengagements Occurring During Autonomous Vehicle Testing”. In: IEEE/CAA Journal of Automatica Sinica, 5(1), 2018.
- [Merat.2014] Merat, N.; Jamson, A. H.; Lai, F. C.H.; Daly, M.; Carsten, O. M.J.: “Transition to Manual: Driver Behaviour when Resuming Control from a Highly Automated Vehicle”. In: Transp. Res. Part F: Traffic Psychol. Behav., 26, Part B, 2014.
- [Misra.2016] Misra, I.; Shrivastava, A.; Gupta, A.; Hebert, M.: “Cross-Stitch Networks for Multi-Task Learning”. In: Conference on Computer Vision and Pattern Recognition, IEEE, 2016.
- [Na.2013] Na, X.; Cole, D. J.: “Linear Quadratic Game and Non-Cooperative Predictive Methods for Potential Application to Modelling Driver – AFS Interactive Steering Control”. In: Vehicle System Dynamics, 51(2), 2013.
- [Oh.2005] Oh, C.; Oh, J.-S.; Ritchie, S.: “Real-Time Hazardous Traffic Condition Warning System: Framework and Evaluation”. In: IEEE Transactions on Intelligent Transportation Systems, 6(3), IEEE, 2005.
- [Ohn-Bar.2014] Ohn-Bar, E.; Martin, S.; Tawari, A.; Trivedi, M. M.: “Head, Eye, and Hand Patterns for Driver Activity Recognition”. In: International Conference on Pattern Recognition, IEEE, 2014.
- [Ohn-Bar.2015] Ohn-Bar, E.; Trivedi, M. M.: “A Comparative Study of Color and Depth Features for Hand Gesture Recognition in Naturalistic Driving Settings”. In: Intelligent Vehicles Symposium (IV), IEEE, 2015.
- [Pilutti.1999] Pilutti, T.; Ulsoy, A.: “Identification of Driver State for Lane-keeping Tasks”. In: IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans, 29(5), IEEE, 1999.
- [SAE.2014] Society of Automotive Engineers (SAE): “Taxonomy and Definitions for Terms Related to On-Road Motor Vehicle Automated Driving Systems”. SAE J3016, 2014.
- [Saito.2017] Saito, T.; Wada, T.; Sonoda, K.: “Control Transferring between Automated and Manual Driving using Shared Control”. In: International Conference on Automotive User Interfaces and Interactive Vehicular Applications Adjunct (ACM), 2017.

- [Saito.2018] Saito, T.; Wada, T.; Sonoda, K.: “Control Authority Transfer Method for Automated-to-Manual Driving via Shared Authority Mode”. In: *IEEE Transactions on Intelligent Vehicles*, 3(2), IEEE, 2018.
- [Simonyan.2015] Simonyan, K.; Zisserman, A.: “Two-stream Convolutional Networks for Action Recognition in Videos”. In: *Advances in Neural Information Processing Systems*, 2014.
- [Tamaddoni.2011] Tamaddoni, S. H.; Ahmadian, M.; Taheri, S.: “Optimal Vehicle Stability Control Design Based on Preview Game Theory Concept”. In: *American Control Conference (ACC)*, 2011.
- [Tapia.2013] Tapia-Espinoza, R.; Torres-Torriti, M.: “Robust Lane Sensing and Departure Warning under Shadows and Occlusions”. In: *Sensors*, 13(3), 2013.
- [Todorov.2002] Todorov, E.; Jordan, M. I.: “Optimal Feedback Control as a Theory of Motor Coordination”. In: *Nature Neuroscience*, 5(11), 2002
- [Torkkola.2004] Torkkola, K.; Massey, N.; Wood, C.: “Driver Inattention Detection through Intelligent Analysis of Readily Available Sensors”. In: *International Conference on Intelligent Transportation Systems*, IEEE, 2004.
- [Tran.2015] Tran, D.; Bourdev, L.; Fergus, R.; Torresani, L.; Paluri, M.: “Learning Spatiotemporal Features with 3D Convolutional Networks”. In: *International Conference on Computer Vision*, IEEE, 2015.
- [Wada.2016] Wada, T.; Sonoda, K.; Okasaka, T.; Saito, T.: “Authority Transfer Method from Automated to Manual Driving via Haptic Shared Control”. In: *International Conference on Systems, Man, and Cybernetics (SMC)*, IEEE, 2016.
- [Wang.2010] Wang, J.-G.; Lin, C.-J.; Chen, S.-M.: “Applying Fuzzy Method to Vision-Based Lane Detection and Departure Warning System”. In: *Expert Systems with Application*, 37(1), 2010.
- [Winner.2009] Winner, H.; Hakuli, S.; Wolf, G.: “Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort”. Springer, 2009.
- [Wu.2012] Wu, C.-F.; Lin, C.-J.; Lee, C.-Y.: “Applying a Functional Neurofuzzy Network to Real-Time Lane Detection and Front-Vehicle Distance Measurement”. In: *IEEE Transactions on Systems, Man and Cybernetics, Part C: Applications and Reviews*, 42(4), IEEE, 2012.
- [Yan.2016] Yan, S.; Teng, Y.; Smith, J. S.; Zhang, B.: “Driver Behavior Recognition Based on Deep Convolutional Neural Networks”. In: *International Conference on Natural Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, IEEE, 2016.
- [Zhong.2007] Zhong, Y.-J.; Du, L.-P.; Zhang, K.; Sun, X.-H.: “Localized Energy Study for Analyzing Driver Fatigue State Based on Wavelet Analysis”. In: *International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR)*, 2007.



## Berichtsblatt

1. ISBN oder ISSN -	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel  Schlussbericht des Karlsruher Instituts für Technologie (KIT) für das BMBF-Forschungsvorhaben „Personalisierte, adaptive, kooperative Systeme für automatisierte Fahrzeuge“ (PAKoS)	
4. Autor(en) [Name(n), Vorname(n)]  Flad, Michael; Ludwig, Julian; Roitberg, Alina; Karg, Philipp; Stiefelhagen, Rainer; Hohmann, Sören	5. Abschlussdatum des Vorhabens 31.12.2019
	6. Veröffentlichungsdatum -
	7. Form der Publikation -
8. Durchführende Institution(en) (Name, Adresse)  Karlsruher Institut für Technologie (KIT) Kaiserstraße 12 76131 Karlsruhe	9. Ber. Nr. Durchführende Institution -
	10. Förderkennzeichen 16SV7675K
	11. Seitenzahl 52
12. Fördernde Institution (Name, Adresse)  Bundesministerium für Bildung und Forschung (BMBF) 53170 Bonn	13. Literaturangaben 60
	14. Tabellen 4
	15. Abbildungen 34
16. Zusätzliche Angaben -	
17. Vorgelegt bei (Titel, Ort, Datum) -	
18. Kurzfassung Automatisierte Fahrzeuge werden den Fahrer in Zukunft nicht nur unterstützen, sondern streckenweise ganz von der Verantwortung über die Fahraufgabe befreien. Allerdings ist an den Systemgrenzen oder bei einer Degradation weiterhin die Rückgabe der Fahrzeugkontrolle an den Menschen vorgesehen. Mehrere Studien legen jedoch nahe, dass ein, während der automatisierten Fahrt unaufmerksamer und mit Nebentätigkeiten beschäftigter, Fahrer bei einer Übernahmeaufforderung nur eine unzureichende Fahrbereitschaft aufweist, was in ausbleibenden oder gefährlichen Reaktionen resultiert. Im Rahmen des Projekts PAKoS entwickelte das KIT ein neuartiges Regelungskonzept, um diese Kontrollübergabe durch eine kooperative Transitionsphase zu gestalten. In dieser Phase steuern Mensch und Automation gemeinsam das Fahrzeug und die Automation unterstützt damit den Fahrer bis er seine volle mentale Leistungsfähigkeit erlangt hat. Um eine Anpassung an die individuellen Charakteristiken des Fahrers und seine Tätigkeiten vor der Übernahmeaufforderung zu ermöglichen, ist eine Erfassung und Interpretation des Fahrzeuginnenraums entscheidend. Deshalb entwickelte das KIT zudem Deep-Learning-basierte Modelle zur Erkennung der Aktivitäten des Fahrers mittels Kameradaten. In Fahrsimulatorstudien zeigt sich eine statistisch signifikante Verbesserung des entworfenen Transitionskonzeptes im Vergleich zur direkten Abschaltung der Automation (Stand der Technik) in Bezug auf sicherheitsrelevante Kenngrößen. Der generierte Datensatz für die Aktivitätserkennung (Drive&Act) bildet die Basis für das Training der entwickelten Erkennungsmodelle, welche verbesserte Resultate erzielen als bisherige Methoden.	
19. Schlagwörter Hochautomatisiertes Fahren, Fahrerassistenzsysteme, Mensch-Maschine-Interaktion, Fahreraktivitätserkennung	
20. Verlag -	21. Preis -

## Document Control Sheet

1. ISBN or ISSN -	2. type of document (e.g. report, publication) Final report
3. title  Final report of the Karlsruhe Institute of Technology (KIT) for the research project „Personalized, adaptive, cooperative systems for automated vehicles“ (PAKoS) funded by the German Federal Ministry of Education and Research	
4. author(s) (family name, first name(s))  Flad, Michael; Ludwig, Julian; Roitberg, Alina; Karg, Philipp; Stiefelhagen, Rainer; Hohmann, Sören	5. end of project 31.12.2019
	6. publication date -
	7. form of publication -
8. performing organization(s) (name, address)  Karlsruher Institut für Technologie (KIT) Kaiserstraße 12 76131 Karlsruhe	9. originator's report no. -
	10. reference no. 16SV7675K
	11. no. of pages 52
12. sponsoring agency (name, address)  Bundesministerium für Bildung und Forschung (BMBF) 53170 Bonn	13. no. of references 60
	14. no. of tables 4
	15. no. of figures 34
16. supplementary notes -	
17. presented at (title, place, date) -	
18. abstract In the future, automated vehicles will not only support their drivers but will also take over the complete responsibility for the driving task in some cases. However, at the boundary of the operational domain or in case of failures the control of the vehicle is given back to the human. According to several studies, the human driver will most likely lack situational awareness at the time of the takeover request if he was engaged in secondary activities and inattentive during the automated drive. This leads to missing or dangerous reactions. During the research project PAKoS, the KIT developed a novel control concept to design this control authority shift by means of a cooperative transition phase. In this phase, the human and the automation jointly control the vehicle and the automation supports the driver until he has achieved his full mental readiness. In order to incorporate individual differences between drivers and their activities before the takeover request, capturing and interpreting the interior of the car is of importance. Therefore, the KIT additionally developed driver activity recognition models based on Deep Learning and camera data. Driving studies in the simulator point out that the novel transition concept outperforms the direct shutoff of the automation (state of the art approach). This can be shown with statistical significance regarding relevant safety measures. The recorded set of data for driver activity recognition (Drive&Act) acts as the basis for training the recognition models, which achieve better results as existing methods.	
19. keywords Highly Automated Driving, Advanced Driver Assistance Systems, Human-Machine Interaction, Driver Activity Recognition	
20. publisher -	21. price -