

Autonomes Fahren auf der Autobahn – Eine Potentialstudie für zukünftige Fahrerassistenzsysteme

Dipl.-Ing. Sebastian Rauch, M.Sc. Michael Aeberhard,

Dipl.-Ing. Michael Ardelt, Dr.-Ing. Nico Kämpchen

BMW Group Forschung und Technik

Hanauer Straße 46, 80992 München, Tel.: 089 38260749

{Sebastian.Rauch, Michael.Aeberhard, Michael.Ardelt, Nico.Kaempchen}@bmw.de

Kurzfassung

Automatisiertes Fahren ohne Fahrereingriff auf der Autobahn, Vision oder bereits machbar? Im Rahmen der Technologie-Potentialstudie „hochautomatisiertes Fahren auf der Autobahn (HAF)“ der BMW Group Forschung und Technik wird ein Versuchsfahrzeug für eine hochautomatisierte Autobahnfahrt entwickelt. Die Ergebnisse dieses Forschungsprojekts geben Auskunft über die technische Machbarkeit und heutige Grenzen, vor allem aber wird dabei wertvolles Grundlagenwissen für zukünftige Fahrerassistenzsysteme (FAS) gewonnen.

1 Einleitung und Motivation

Moderne Fahrerassistenzsysteme unterstützen den Fahrer in einer Vielzahl von Situationen, mit dem Ziel, den Fahrer bei seiner täglichen Fahraufgabe zu entlasten. Um das Potential von zukünftigen Fahrerassistenzsystemen besser bewerten zu können, entwickelten die Spezialisten der BMW Group Forschung und Technik ein Forschungsfahrzeug für das hochautomatisierte Fahren auf Autobahnen (Abbildung 1). Der Prototyp ist mit zahlreichen Sensoren ausgestattet, die es ihm ermöglichen, automatisiert ohne Fahrereingriff auf der Autobahn zu fahren. Das System fährt in einem Geschwindigkeitsbereich von 0 – 130 km/h selbständig auf der Autobahn und hält sich dabei an alle Verkehrsregeln. Langsamere Verkehrsteilnehmer werden vom System erkannt und eigenständig überholt, um die vom Fahrer eingestellte Wunschgeschwindigkeit einzuhalten. Für einen optimalen Fahrkomfort der Insassen wurde der Prototyp auf eine sichere und defensive Fahrweise hin optimiert. So verhält sich das System beispielsweise an Autobahneinfahrten kooperativ und lässt auffahrende Fahrzeuge einfädeln, um potentiell kritische Situation bereits im Vorfeld aufzulösen. Das System basiert auf der Verwendung von hochgenauen digitalen Karten. Da derzeit keine Karten mit ausreichender Genauigkeit und Detaillierungsgrad kommerziell verfügbar sind, wurde im Rahmen des Projekts ein Verfahren zum kollektiven Erlernen von hochgenauen Karten mit der Fahrzeugflotte entwickelt und eingesetzt.



Abbildung 1: Hochautomatisiertes Fahren auf der Autobahn

Einige der Kerntechnologien für das hochautomatisierte Fahren wurden bereits in den Vorläufer-Projekten „BMW TrackTrainer“ und „BMW Nothalteassistent“ entwickelt. Der TrackTrainer wurde als Schulungsfahrzeug für Rennstrecken entworfen [1], [2]. Auf abgeschlossenen Rennstrecken ohne andere Verkehrsteilnehmer kann das System bereits völlig autonom, mit Hilfe einer Fusion der Daten aus hochgenauer digitaler Karte, sowie INS/RTK-GPS(GPS + Inertialplattform)- und Kameradaten, auf der Ideallinie ohne Fahrereingriff fahren.

Nach dem Erfolg des BMW TrackTrainers entwickelte die BMW Group Forschung und Technik im Rahmen des Projekts „SmartSenior“, gefördert vom Bundesministerium für Bildung und Forschung, den BMW Nothalteassistent [3]. Bei Gesundheitsbedingter Fahrunfähigkeit des Fahrers, übernimmt das Fahrzeug die Kontrolle und fährt in einem automatisierten Modus auf den Pannestreifen. Anschließend wird automatisch der Nothilfedienst über Zustand und Position von Fahrer und Fahrzeug informiert. Hierbei kommen ähnliche Technologien wie bereits beim BMW TrackTrainer für die Regelung des Fahrzeuges sowie die Lokalisierung zum Einsatz. Da sich der BMW Nothalteassistent im realen Straßenverkehr bewegt, mussten die Technologien für die neue Umgebung erweitert werden. So wurde eine rundum Umfelderfassung zur Erkennung anderer Verkehrsteilnehmer entwickelt. Die Funktionsfähigkeit des BMW Nothalteassistenten wurde erfolgreich auf Teststrecken mit simuliertem Verkehr demonstriert.

Im nächsten Entwicklungsschritt wurde das hochautomatisierte Fahren auf der Autobahn untersucht. Dieser Beitrag stellt die Kerntechnologien für das automatisierte Fahren auf der Autobahn und die Ergebnisse einer hochautomatisierten Fahrt von München nach Ingolstadt vor.

2 Technologien zum hochautomatisierten Fahren

Die Realisierung des hochautomatisierten Fahrens auf der Autobahn setzt einige neue Technologien ein, die in modernen Fahrerassistenzsystemen noch nicht vorhanden sind. Insgesamt vier neue Kerntechnologien wurden für das hochautomatisierte Fahren entwickelt: Die hochgenaue Positionsbestimmung, die Erstellung hochgenauer digitaler Karten, die Umfelderfassung und die Fahrstrategie. Ein Systemüberblick dieser vier Technologien ist in Abbildung 2 illustriert.



Abbildung 2: Kerntechnologien für das hochautomatisierte Fahren auf der Autobahn

In den folgenden Abschnitten werden die Technologien im Detail beschrieben.

2.1 Positionsbestimmung

Bereits im Vorgängerprojekt „BMW TrackTrainer“ wurde eine hochgenaue, dynamische Positionsbestimmung auf einer Rennstrecke ermöglicht. Für das hochautomatisierte Fahren auf der Autobahn ergeben sich neue Herausforderungen. Dementsprechend musste auch die Positionsbestimmung für Autobahnscenarien angepasst beziehungsweise weiterentwickelt werden.

Rennstrecken bestehen meist aus nur einer einzigen, relativ breiten Fahrspur, Autobahnen hingegen bestehen aus mehreren, vergleichsweise schmalen Fahrspuren. Zudem ist das Autobahnnetz wesentlich größer, vielfältiger und komplexer. So muss eine robuste und hochverfügbare Lokalisierung für wesentlich längere Strecken mit Ein- und Ausfahrten, Autobahnkreuzen und Tunnelabschnitten realisiert werden.

Um beim hochautomatisierten Fahren die Beeinträchtigung anderer Verkehrsteilnehmer möglichst ausschließen zu können, ist es entscheidend, dass das Fahrzeug zentimetergenau in der eigenen Fahrspur geführt wird. Dementsprechend liegt auch der maximal tolerierbare Fehler bei der Positionsbestimmung im Zentimeterbereich. Ein Sensor alleine kann nicht alle Anforderungen an die Positionsbestimmung hinsichtlich Verfügbarkeit, Robustheit und Genauigkeit erfüllen. Aus diesem Grund wurde für die Positionsbestimmung ein Fusionskonzept aus Satellitennavigation, spurrelativer Landmarkennavigation und einer hochgenauen digitalen Karte umgesetzt (Abbildung 3). DGNSS, gestützt durch Odometriedaten, erlaubt die Bestimmung der absoluten Position und das Matchen in eine hochgenaue digitale Karte. Mit einer kamerabasierten Fahrspurerkennung sowie einer laserscannerbasierten Fahrspur- und Randbebauungserkennung wird die spurrelative Position, also der Abstand und die Orientierung zu den linken und rechten Fahrspurmarkierungen beziehungsweise den Randbebauungen, sehr genau erfasst. Ein Kalman-Filter fusioniert die absolute DGNSS Position mit der spurrelativen Position – gestützt durch die digitale Karte – und erlaubt somit eine zentimetergenaue, hochverfügbare und robuste Echtzeit-Positionsbestimmung auf der Autobahn. In der digitalen Karte sind neben allen relevanten

Fahrspuren und Randbebauungen auch exakte Kurvenradien hinterlegt. Diese Informationen stehen beim automatisierten Fahren mit einem großen Vorausschau-Horizont zur Verfügung und ermöglichen die Planung von Spurwechselmanövern sowie die Realisierung einer optimalen Regelperformance.



Abbildung 3: Hochgenaue Positionsbestimmung auf Autobahnen durch Sensorfusion

2.2 Erstellung von hochgenauen digitalen Karten

Da aktuell keine digitalen Karten mit einer ausreichenden Genauigkeit beziehungsweise mit einem ausreichenden Detaillierungsgrad kommerziell verfügbar sind, mussten die Karten für das Projekt eigens erstellt werden. Zu diesem Zweck wurde ein Verfahren zum Erlernen hochgenauer digitaler Karten entwickelt. Idee ist es, einen Streckenabschnitt mit der Fahrzeugflotte mehrfach zu befahren, um anschließend aus den gewonnenen Fahrzeugsensordaten eine hochgenaue Karte zu generieren.

Die Problemstellung, eine hochgenaue Karte mit einem bewegten Fahrzeug, welches seine eigene Position nicht exakt kennt, zu generieren, ist in der Robotik unter dem Begriff SLAM (Simultaneous Localization and Mapping) bekannt. Im Rahmen des Projekts kommt ein sogenanntes GraphSLAM-Verfahren zum Einsatz [4]. Alle relevanten Messdaten (GNSS-, Odometrie-, Spur- und Randbebauungserkennungsdaten) werden von der Fahrzeugflotte aufgezeichnet und anschließend für die Kartenerstellung bereitgestellt. Sobald es für einen Streckenabschnitt ausreichend Messdaten gibt wird ein sogenannter Informationsgraph, bestehend aus Knoten und Kanten, erstellt. Die Knoten des Graphen repräsentieren die jeweils gefahrene Fahrzeugtrajektorie und die dabei erkannten Landmarken (Spurmarkierungen und Randbebauungen). Zwischen den Knoten werden Kanten gebildet; diese Kanten formulieren Bedingungen anhand von GNSS-, Odometrie- oder Landmarkenmessungen. Das wiederholte Erkennen von Spurmarkierungen bei verschiedenen Fahrten wird durch das Bilden von Assoziationen zwischen zwei Landmarken-Knoten im Informationsgraphen berücksichtigt (Abbildung 4).




Abbildung 4: Messdaten und zugehöriger Informationsgraph (grün: Landmarken, blau: Trajektorie, rot: GNSS)

Durch eine Optimierung des Graphen erhält man als Ergebnis eine optimale Schätzung der Lage der Landmarken (Fahrspurmarkierungen und Randbebauungen). Abschließend werden diese in der fertigen Karte zentimetergenau, aber speichereffizient als Merkmale hinterlegt und stehen für das hochautomatisierte Fahren zur Verfügung (Abbildung 5).





Abbildung 5: Hochgenaue digitale Karte

Das Beispiel in Abbildung 6 demonstriert die Anwendung des GraphSLAM-Verfahrens bei der Kartierung eines etwa einen Kilometer langen Autobahntunnels. Die Rohdaten zeigen deutlich, dass es bei der Messdatenaufzeichnung, trotz der Verwendung eines hochwertigen INS/RTK-GNSS Positionierungssystems, am Ende des Tunnels zu erheblichen Fehlern in der Positionsschätzung kommt. Die Rohdaten-Trajektorien weisen einen Fehler von bis zu 20 Metern auf; zudem ist am Ende des Tunnels die Anordnung der Fahrspuren vertauscht (Abbildung 6a). Eine direkte Kartenerstellung anhand der Rohdaten ist somit nicht möglich.



(a)



(b)

Abbildung 6: Fehlerhafte Trajektorien bei Tunneldurchfahrt (a) und GraphSLAM Resultat (b)

Das GraphSLAM-Verfahren erlaubt dennoch – trotz erheblicher Messunsicherheiten – die Erstellung einer sehr genauen Karte. Abbildung 6b zeigt das Ergebnis des GraphSLAM-Verfahrens: Sowohl die relative Lage, als auch die absolute Lage der Fahrspuren konnte für dieses anspruchsvolle Tunnelszenario korrekt berechnet werden.

2.3 Umfelderkennung

Eine große Herausforderung des hochautomatisierten Fahrens besteht darin, dass sich das Fahrzeug im realen Verkehr auf der Autobahn selbständig bewegen soll. Dazu ist eine zuverlässige Umfelderkennung notwendig um alle anderen Verkehrsteilnehmer rundum das Fahrzeug zu erkennen. Fahrzeugintegrierte und möglichst seriennahe Sensoren werden angewendet um die Umfelderkennung zu realisieren. Bis zu 12 Sensoren (4 Laserscanner, 3 Radar, 4 Ultraschall und eine Kamera) werden eingesetzt, wie in Abbildung 7 dargestellt ist. Jeder Bereich des Fahrzeuges wird von mehreren Sensoren, unter der Verwendung verschiedener Messprinzipien, beobachtet. Der Einsatz redundanter Sensoren im gesamten Fahrzeugumfeld garantiert Zuverlässigkeit und Robustheit.




Abbildung 7: Umfelderkennung für das hochautomatisierte Fahren mit 12 fahrzeugintegrierte Sensoren

Daraus ergibt sich das Problem, die Daten von mehreren Sensoren zu verarbeiten, um eine einheitliche, Sensor-unabhängige Repräsentation aller erkannten Verkehrsteilnehmer zu erreichen. Eine High-Level Sensordaten Fusionsarchitektur (Abbildung 8) wird angewendet, um Sensordaten auf Objektebene zu einer globalen Objektliste zusammen zu fusionieren [5]. Die Architektur ist auf drei Verarbeitungsebenen aufgeteilt: Sensor, Fusion und Funktion. Auf der Sensorebene verarbeitet jeder Sensor seine eigenen Daten und stellt Objekte dar, die der Sensor im Sichtbereich erfasst hat. Diese einzelnen Sensorobjektlisten werden auf der Fusionsebene mittels Track-to-Track Fusionsalgorithmen kombiniert. Zum Einsatz kommt der Informationsmatrix-Fusionsalgorithmus um den Zustand und die Kovarianz mehrerer Sensoren für das gleiche Objekt zu fusionieren [6]. Die Existenzwahrscheinlichkeiten werden mithilfe der Dempster-Shafer Evidenztheorie fusioniert [7]. Diese fusionierte globale Objektliste ist auf der Funktionsebene für verschiedene Funktionen verfügbar.

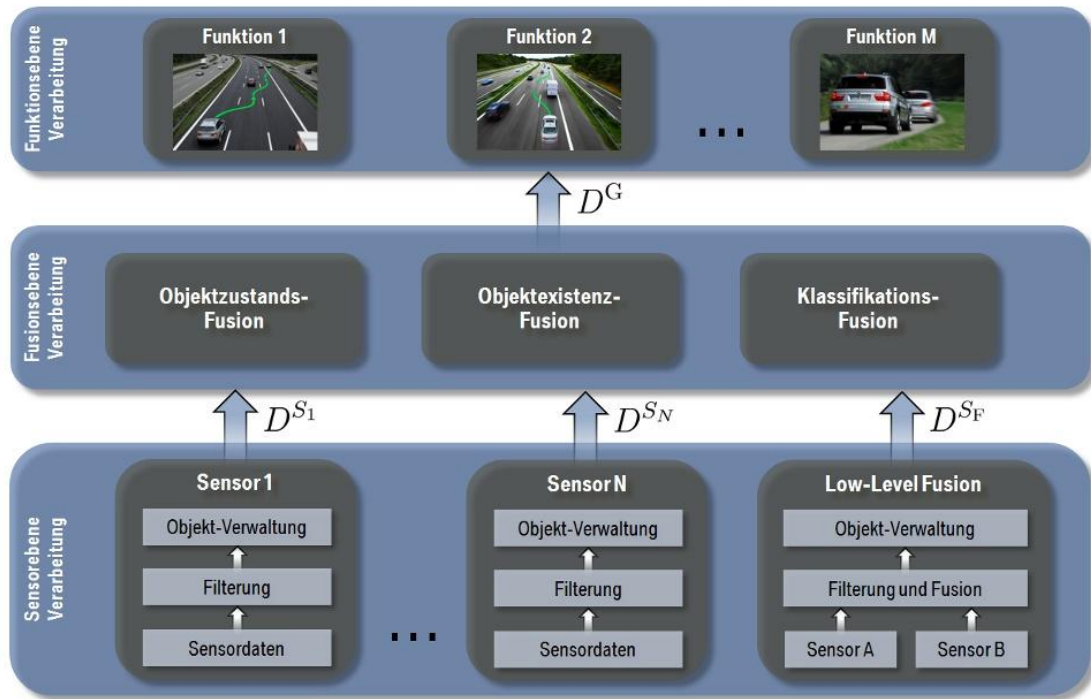


Abbildung 8: High-Level Sensordaten Fusions-Architektur [5]

Das hochautomatisierte Fahren beispielsweise, ordnet die Objekte der globalen Objektliste mithilfe der Fahrzeugeigenlokalisierung und der digitalen Karte den Fahrspuren zu und leitet davon eine Fahrstrategie ab. Eine hohe Genauigkeit der Objekterkennung ist nötig, damit die erkannten Verkehrsteilnehmer den richtigen Fahrspuren zuverlässig zugeordnet werden. Die Genauigkeit der Umfelderkennung wurde in einem Testszenario auf einer geschlossenen Teststrecke evaluiert. Ein Überholmanöver wurde mit einem zweiten Fahrzeug durchgeführt, so dass sich das erfasste Objekt durch den Sichtbereich aller Sensoren bewegte. Beide Fahrzeuge wurden mit hochgenauem Differential-GNSS mit integrierter Inertialplattform ausgestattet. Dieses System kann die globale Position bis zu 2cm genau bestimmen. Damit ist es möglich, die relative Position des erfassten Fahrzeugs zu berechnen, um eine Referenz für die Bewertung der Objekterkennung herzustellen.

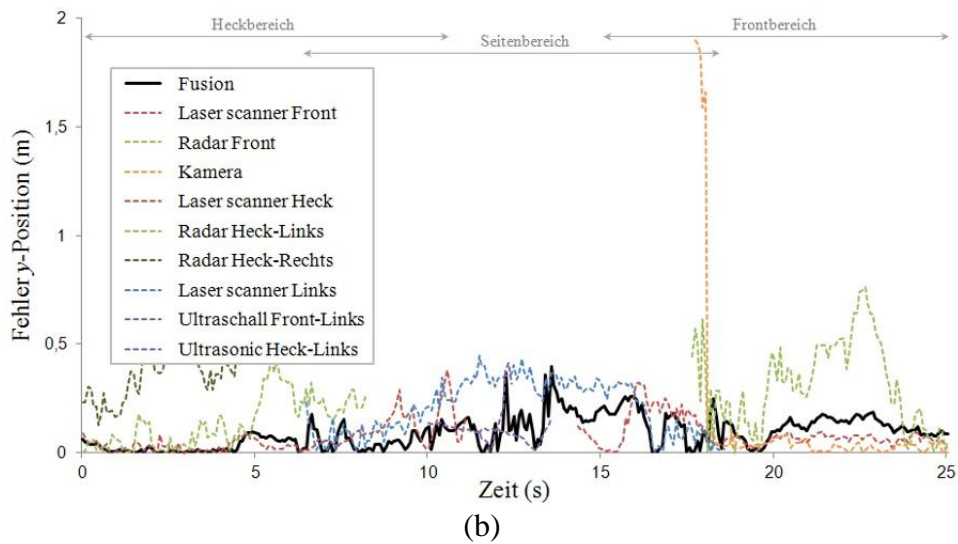
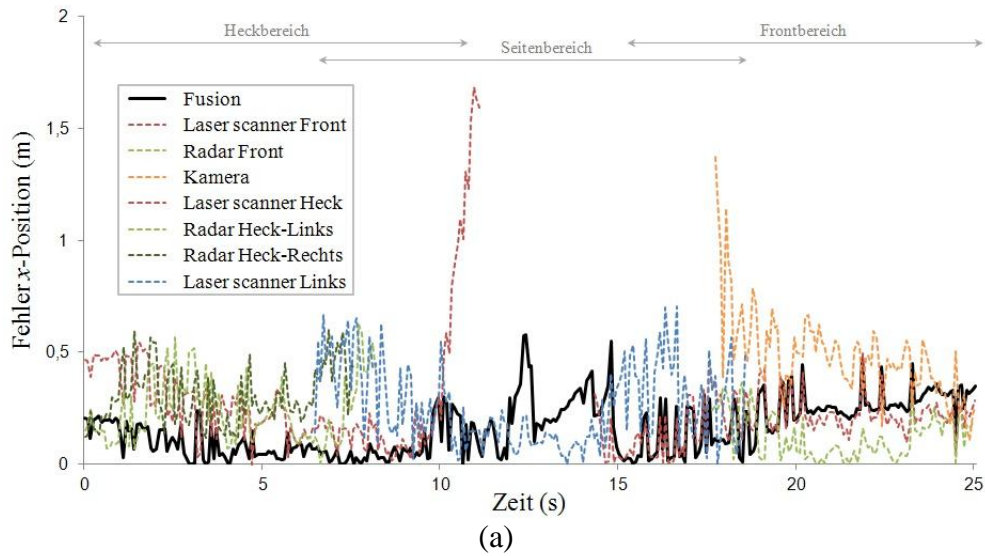


Abbildung 9: Positionsfehler der Sensoren sowie die Fusion in der Längs- (a) und Querrichtung (b) während eines Überholdmanövers

In Abbildung 9 ist der Fehler in der Position in der Längs- und Querrichtung während des gesamten Überholmanövers dargestellt. Am Anfang des Manövers befindet sich das erfasste Fahrzeug im Erfassungsbereich der Hecksensoren des Egofahrzeugs. Bei $t = 6\text{s}$ beginnt die Erfassung mit den Seitenbereichssensoren und bei $t = 15\text{s}$ wird das Fahrzeug von den Sensoren im Frontbereich erfasst. Insgesamt wird das Fahrzeug von neun verschiedenen Sensoren während des Überholmanövers gesehen. Der Fehler in der Längsposition bleibt während des Testszenarios im Wesentlichen unter $0,5\text{m}$, außer für einen kleinen Zeitraum, in dem sich das überholende Fahrzeug im Seitenbereich befindet. Ähnliche Ergebnisse sind bei der Querposition zu finden. Nur im Seitenbereich erhöht sich der Fehler in der Position, da die Herausforderungen für das Tracking für den Seitenbereichssensor groß sind. Im Front- und Heckbereich liegt der Querpositionsfehler unterhalb $0,2\text{m}$, eine Genauigkeit, die eine zuverlässige Fahrspurzuordnung für die Fahrstrategie erlaubt.

2.4 Fahrstrategie

Auf Basis der Lokalisierung, digitaler Karte, und der Umfelderkennung entscheidet die Fahrstrategie, wie sich das Fahrzeug im Straßenverkehr verhalten soll und ermittelt die Sollwerte für die Fahrzeugregelung. Die Fahrstrategie wird realisiert durch ein Netzwerk hybrider Automaten, die sich in diskrete Zustände mithilfe von Entscheidungsbäumen schalten [8], [9].

Zwei Hybride Automaten werden für das hochautomatisierte Fahren eingesetzt: Einer für die Querführung, der andere für die Längsführung. Die möglichen Zustände der zwei Automaten sind in Tabelle 1 aufgelistet.

Tabelle 1: Zustände der Fahrstrategie für die Quer- und Längsführung

	Querführung	Längsführung
0	off	off
1	Lane Keeping	DCC
2	LCGA (links)	ACC
3	LCGA (rechts)	LCGA
4	Lane Change (links)	Critical Control
5	Lane Change (rechts)	
6	LC-Abort (links)	
7	LC-Abort (rechts)	

Die Querführung besteht aus acht möglichen Zuständen: *System off*, *Lane Keeping*, *Lane Change Gap Approach (LCGA)* (links und rechts), *Lane Change* (links und rechts), und *Lane Change Abort* (links und rechts). *Lane Keeping* ist der einfachste Zustand. In diesem Zustand hält sich das Fahrzeug in der eigenen Spur. Falls ein Fahrspurwechsel gewünscht ist, dieser jedoch auf Grund der Verkehrssituation nicht möglich ist, befindet sich die Quer- und Längsführung im *Lane Change Gap Approach* Zustand. In diesem Zustand werden Fahrstrategien zur Umsetzung von Spurwechselmanövern ausgeführt, beispielsweise eine Lücke ansteuern, oder das eigene Fahrzeug in der Spur nach links oder rechts bewegen, um dadurch einen Spurwechselwunsch für andere Verkehrsteilnehmer anzudeuten. Wenn ein Spurwechsel gewünscht ist und die Situation es erlaubt, wird der *Lane Change* Zustand in der Querführung ausgewählt, und eine kontinuierliche Spurwechseltrajektorie berechnet. Falls während einem Spurwechsel die Verkehrssituation den Spurwechsel verhindert, kann das System mit dem Zustand *Lane Change Abort* den Spurwechsel abbrechen und das Fahrzeug fährt in die vorherige Spur zurück.

Die Längsführung besteht aus fünf Zuständen: *System off*, *Dynamic Cruise Control (DCC)*, *Active Cruise Control (ACC)*, *Lane Change Gap Approach (LCGA)* und *Critical Control*. Bei DCC gibt es kein Vorderfahrzeug und das Eigenfahrzeug hält die vom Fahrer eingegebene gewünschte Geschwindigkeit ein. Mit ACC wird die Geschwindigkeit an ein Zielobjekt (z.B. Vorderfahrzeug) angepasst. Das Zielobjekt, z.B. während eines Spurwechsels, kann auch das Vorderfahrzeug einer Nachbarspur sein. Der Zustand *Critical Control* wird in kritischen Situationen aktiviert, z.B. wenn ein anderes Fahrzeug knapp einschert, und erlaubt eine höhere Dynamik der Längsführung um kritische Situationen zu beherrschen.




Abbildung 10: Umfeldbeschreibung für die Situationsinterpretation

Die Entscheidungen für die Zustände werden anhand der Verkehrssituation getroffen. Eine Umfeldbeschreibung, die in Abbildung 10 dargestellt ist, wurde für die Situationsinterpretation entwickelt. Das Umfeld ist damit in 8 Bereiche aufgeteilt, die belegt oder frei sein können. Die Objekte der Umfelderkennung werden auf Basis der Fahrzeugeigenlokalisierung und der digitalen Karte den Fahrspuren zugeordnet. Auf diese Weise kann der Belegungsstatus für die Situationsinterpretation bestimmt werden. Diese Belegung hängt zudem von einer zeitliche Prädiktion der Objektdaten ab, sowie deren Zustandsunsicherheiten. Dies ermöglicht zuverlässige und robuste Entscheidungen bei der Fahrzeugführung und bei der Ausführung von Fahrspurwechselmanövern.

3 Ergebnisse

Die beschriebenen Technologien wurden in einem prototypischen Fahrzeug eingebaut und realisiert. Dieses Fahrzeug (Abbildung 11) ermöglicht Versuchsfahrten des hochautomatisierten Fahrsystems auf Teststrecken und im realen Verkehr auf der Autobahn.



Abbildung 11: Versuchsfahrzeug für das hochautomatisiertes Fahren auf der Autobahn

Bevor man sich im realen Autobahnverkehr bewegt hat, wurde das System auf einer geschlossenen Teststrecke mit weiteren Fahrzeugen in einer Vielzahl von Situationen getestet und geprüft. Nachdem diese Tests erfolgreich waren, wurde das Gesamtsystem auf der Autobahn A9 zwischen München und Ingolstadt getestet und evaluiert. Ziel war es die ganze Strecke ohne Fahrereingriff zurückzulegen. Am 16. Juni 2011 wurde dieses Ziel zum ersten Mal erreicht. Die Ergebnisse dieser Fahrt werden in diesem Abschnitt vorgestellt.




Abbildung 12: Visualisierung des Umfelds mit Objekten (blau) und digitaler Karte, sowie der Fahrstrategie (unten links und rechts) während eines Überholmanövers

Die gesamte Strecke zwischen München und Ingolstadt beträgt circa 65 km mit zwei bis vier Fahrspuren. Das System hat diese Fahrt in circa 40 Minuten geschafft, komplett automatisiert und ohne Fahrereingriff. Während der Fahrt herrschte stets dichter Verkehr, jedoch kam es zu keiner Stausituation. Die Visualisierung der Objektdaten, der digitalen Karte und der Fahrstrategie während eines Überholmanövers im realen Verkehr ist in Abbildung 12 dargestellt.

Während der Fahrt wurden 32 automatisierte Fahrspurwechselmanöver ausgeführt. Die meiste Zeit war der Querführungszustand Spurhalten aktiv. Vor einigen Überholmanövern wurde zudem der Zustand Lückenansteuerung Links von der Fahrstrategie ausgewählt, um einen zunächst nicht möglichen Fahrspurwechsel zu ermöglichen. Ein Fahrspurwechsel musste während der Fahrt nie abgebrochen werden. Dies zeigt die Zuverlässigkeit der Entscheidungen bezüglich der Ausführung von Spurwechselmanövern. Seit diesem Erfolg wurden bereits einige tausend Kilometer ohne Fahrereingriff auf der Autobahn zurückgelegt.

4 Zusammenfassung und Ausblick

Im Rahmen der Technologiestudie „Hochautomatisiertes Fahren“ konnte die technische Machbarkeit des automatisierten Fahrens auf der Autobahn demonstriert werden. Dennoch hat diese Studie auch klar die Grenzen der heutigen Technologien aufgezeigt.

Es gibt einige Situation im realen Straßenverkehr, die das vorgestellte System noch nicht selbständig bewältigen kann. So können derzeit beispielsweise keine Baustellen erkannt beziehungsweise automatisiert durchfahren werden. Eine Vielzahl von Sondersituationen, wie etwa verlorene Ladung oder ein geplatzter LKW-Reifen, erfordern eine schnelle,

umsichtige und situationsspezifische Reaktion. Die sichere Beherrschbarkeit dieser Sonderereignisse wird eine der maßgeblichen Herausforderungen für die zukünftige Entwicklung automatisierter Systeme sein. Zudem müssen neue rechtliche Rahmenbedingungen geschaffen werden, um den Weg für hochautomatisierte Fahrerassistenzsysteme zu ebnen. Dennoch haben bereits heute einige der führenden Automobil-Hersteller die Einführung der ersten automatisierten Fahrfunktion für den Niedergeschwindigkeitsbereich angekündigt. Ein Beispiel hierfür ist der im BMW i3 Concept vorgestellte Stauassistent.

5 Literatur

- [1] P. Waldmann, Entwicklung eines Fahrzeugführungssystems zum Erlernen der Ideallinie auf Rennstrecken, Bd. 1, Shaker Verlag, 2009.
- [2] P. Waldmann und D. Niehues, „Der BMW TrackTrainer - automatisiertes Fahren im Grenzbereich auf der Nürburgring Nordschleife,“ in s *4. Tagung Sicherheit durch Fahrerassistenz*, München, 2010.
- [3] N. Kaempchen, M. Aeberhard, P. Waldmann, M. Ardelt und S. Rauch, „Der BMW Nothalteassistent: Hochautomatisiertes Fahren für mehr Sicherheit im Straßenverkehr,“ *Elektronik Automotive*, Nr. 8/9, pp. 26-29, Juni 2011.
- [4] S. Rauch, A. Savkin, T. Schaller und P. Hecket, „Hochgenaue Fahrzeuglokalisierung und kollektives Erlernen hochgenauer digitaler Karten,“ in s *AAET*, Braunschweig, 2012.
- [5] M. Aeberhard und N. Kaempchen, „High-Level Sensor Data Fusion Architecture for Vehicle Surround Environment Perception,“ in s *8th International Workshop on Intelligent Transportation*, Hamburg, 2011.
- [6] M. Aeberhard, A. Rauch, M. Rabiega, N. Kaempchen und T. Bertram, „Track-to-Track Fusion with Asynchronous Sensors and Out-of-Sequence Tracks using Information Matrix Fusion for Advanced Driver Assistance Systems,“ in s *IEEE Intelligent Vehicles Symposium*, Alcalá, Spanien, 2012.
- [7] M. Aeberhard, S. Paul, N. Kaempchen und T. Bertram, „Object Existence Probability Fusion using Dempster-Shafer Theory in a High-Level Sensor Data Fusion Architecture,“ in s *IEEE Intelligent Vehicles Symposium*, Baden-Baden, 2011.
- [8] M. Ardelt, P. Waldmann, N. Kaempchen und F. Homm, „Strategic Decision Making Process in Advanced Driver Assistance Systems,“ in s *Proceedings of the International Federation of Automatic Control Symposium on Advances in Automotive Control*, München, 2010.
- [9] M. Ardelt und P. Waldmann, „Hybrides Steuerungs- und Regelkonzept für das hochautomatisierte Fahren auf Autobahnen,“ *at - Automatisierungstechnik*, Bd. 59, Nr. 12, Dezember 2011.