

Fahrerspezifische Analyse des Fahrverhaltens zur Parametrierung aktiver Sicherheitssysteme

Colin Bauer

Carmeq GmbH, Freie Universität Berlin
Berlin
colin.bauer@carmeq.com

Dr. Mark Gonter

Volkswagen AG
Wolfsburg
mark.gonter@volkswagen.de

Prof. Raul Rojas

Freie Universität Berlin
Berlin
raul.rojas@inf.fu-berlin.de

Zusammenfassung

Aktuelle Fahrerassistenzsysteme zur Kollisionsvermeidung oder -minderung gehen in der Situationsanalyse von einem „normalen“ Verhalten des Fahrers aus. Dabei wird angenommen, dass dieses sich jederzeit innerhalb gewisser, von den Entwicklern festgelegten, fahrer- und situationsunabhängigen Grenzen befindet. Assistenzsysteme, die den Fahrstil sowie den aktuellen Zustand des Fahrers berücksichtigen, haben das Potential, deutlich bessere und für den Fahrzeuglenker nachvollziehbarere Hilfen anzubieten.

Die Volkswagen AG untersucht in Zusammenarbeit mit der Freien Universität Berlin und der Carmeq GmbH ein System, das die Parametrierung aktiver Sicherheitssysteme fahrerspezifisch anpasst. Mit Verfahren der Statistik und des Maschinellen Lernens wird ein Modell des Normalverhaltens des Fahrers erstellt. Das Fahrermodell kann nach der Lernphase die Absicht des Fahrers erkennen. Aus der Abweichung des tatsächlichen von dem durch das Modell vorhergesagten Verhalten werden Rückschlüsse zu dem kurzfristigen (aktuelles Fahrmanöver) und langfristigen Fahrerzustand gezogen. Dieser berechnete Fahrerzustand beeinflusst geeignete Parameter des Systems, etwa die akzeptierte Dauer der Untätigkeit des Fahrers bei einem gefährlichen Ereignis. Das Fahrermodell verbessert somit sowohl die Qualität des Assistenzsystems als auch dessen Akzeptanz von Seiten des Autofahrers.

1 Einleitung

In den letzten Jahren haben Fahrerassistenzsysteme zur aktiven Kollisionsvermeidung und -minderung Einzug in die Fahrzeugindustrie gehalten. Erste Systeme dieser Art dienten der Warnung des Fahrers bei gewissen Situationen auf

der Autobahn. Neuere Systeme sind in der Lage, aktiv in das Geschehen einzugreifen und eine Kollision zu verhindern bzw. die Unfallschwere zu reduzieren. Diese Systeme gehen bei der Bestimmung der Gefährlichkeit der Situation in der Regel von einem generischen Verhalten des Fahrers aus. Ein solches System kann die Unterschiede zwischen den Fahrern nicht berücksichtigen. Bei warnenden Assistenzsystemen z.B. könnte eine adaptive Funktion bei einem sportlichen Fahrer später als bei einem konservativen Fahrer warnen, da die Zeitpunkte, an denen die Fahrer ihre Komfortbereiche verlassen, individuell unterschiedlich sind. Auch bei aktiven Sicherheitssystemen können Modelle des Fahrerverhaltens den Zeitpunkt der Auslöseentscheidung positiv beeinflussen. Solche Systeme greifen in der Regel erst spät autonom ein, da nur so sichergestellt werden kann, dass unabhängig des Leistungsvermögens des Fahrers akute Kollisionsgefahr besteht. Bei einem ungeübten Fahrer könnte eine adaptive Sicherheitsfunktion früher und daher noch effektiver eingreifen. Um diese positive Wirkung zu untersuchen wird hier ein System vorgestellt, das ein Modell des Fahrers während der Fahrt erstellt und aus diesem Modell heraus aktive Sicherheitssysteme fahrerspezifisch anpassen kann.

2 Fahrermodellierung

Zuerst einmal ist es aber notwendig zu definieren, was unter Fahrermodellierung verstanden wird. Die Fahrermodellierung in diesem Kontext beschäftigt sich mit der Analyse und Modellierung des Fahrerverhaltens in Interaktion mit dem Fahrzeug und der Umgebung. Andere Möglichkeiten der Modellierung des Fahrers sind etwa Fahrertypklassifikation, Risikobereitschaftsanalyse oder Fahrerzustandserkennung. Die Anzahl der Faktoren, die einen potentiellen Einfluss auf die Fahraufgabe haben, ist so groß, dass sich die Modellierung üblicherweise auf bestimmte Aspekte konzentriert.

Nach [4] kann Fahrermodellierung mit Fokus auf das Fahrerverhalten bei größter Abstraktion in die strategische, die taktische und die Kontrollebene aufgeteilt werden.

Die strategische Ebene befasst sich hauptsächlich mit Routenplanung und kann zeitlich von mehreren Minuten zu mehreren Stunden reichen. Bei der Planung spielen allgemeine Faktoren wie Fahrdauer oder Kosten, aber auch personenspezifische Faktoren wie Komfort eine Rolle.

Die taktische Ebene beschreibt einzelne Fahrmanöver, die sich zeitlich auf wenige Sekunden beschränken. Fahrermodellierung im Sinne der taktischen Ebene ist die Modellierung von Manövern wie Überholen oder Abbiegen. Die Analyse solcher Modelle liefert Informationen über die Fahrweise des Fahrers.

Die Fahrermodellierung in der Kontrollebene untersucht, wie der Fahrer das Fahrzeug bewegt, um die Fahrmanöver durchzuführen. Diese Modelle sind üblicherweise mathematische Regler für die jeweiligen Stellgrößen wie Geschwindigkeit oder Lenkwinkel, die fahrerspezifisch dem Fahrstil des Fahrers entsprechend angepasst werden. Historisch gesehen wird unter dem Begriff Fahrermodell diese

letzte Ebene verstanden.

Hier wird die Fahrermodellierung als Modellierung von Manövern, also die taktische Ebene, betrachtet. Diese Ebene bietet ein hohes Potential für die fahrerspezifische Anpassung von Sicherheits- und Assistenzsystemen.

3 Fahrmanöverprädiktion

Ein Fahrermodell besteht in dem Kontext dieser Arbeit aus einzelnen Modulen, die jeweils ein Fahrmanöver repräsentieren. Dieser Abschnitt beschreibt das Verfahren, das während der Fahrt automatisch ein Modell für ein Manöver erstellt. Es basiert auf Fuzzy Logic [9], ein weit verbreitete Methode des Maschinellen Lernens. Maschinellen Lernverfahren, die bisher zur Manöverprädiktion angewandt wurden, sind u.A. Fuzzy Logic [1], Bayes'sche Netze [2] oder Hidden Markov Models ([5],[2]).

Wie mit klassischer Logik ist es bei Fuzzy Logic möglich, mit Hilfe geeigneter Regeln aus den Werten der Eingangsvariablen auf ein Ergebnis (in unserem Fall ein Manöver) zu schließen. Der Vorteil von Fuzzy Logic ist, dass die Werte der Eingangsvariablen unscharfe Grenzen haben können. Ein „Abstand“ ist nicht nur entweder „nah“ oder „weit“, sondern kann zu „nah“ mit 0.8 und „weit“ mit 0.2 zugehörig sein, was dem menschlichen Denken mehr entspricht als die traditionelle binäre Logik. Diese Eigenschaft von Fuzzy Logic, die Tatsache, dass Fahrmanöver stark regelbasiert durchgeführt werden und die gute Interpretierbarkeit der Ergebnisse haben den Ausschlag für Fuzzy Logic im Vergleich mit anderen Lernmethoden gegeben.

Um ein fahrerspezifisches Modell eines Manöver mit Fuzzy Logic zu erstellen sind drei Schritte notwendig:

1. Bestimmung der relevanten Eingangsvariablen für das Manöver.
2. Fahrerspezifische Einteilung der Eingangsvariablen in eine Menge von Fuzzy Sets, die diese unscharf beschreiben.
3. Fahrerspezifische Generierung einer Regelbasis anhand von Beispielmanövern.

Es gibt verschiedene Möglichkeiten, die Eingangsvariablen zu bestimmen. Werden mehrere Manöver gleichzeitig betrachtet, können die Variablen gewählt werden, die die Manöver am besten voneinander trennen, wie z.B. bei [1] dargestellt. Eine weitere Methode ist, alle denkbaren Variablen zu berücksichtigen und nach dem Lernvorgang anhand der Regelbasis die irrelevanten Eingangsgrößen wieder zu entfernen. Dies hätte den Vorteil, dass für jeden Fahrer nur die für ihn relevanten Variablen übrigbleiben. Der Nachteil ist jedoch eine sehr große Regelbasis. Derzeit werden die Eingangsvariablen eines Manövermodells

im Vorfeld durch Expertenwissen bestimmt, in Zukunft ist jedoch eine automatisierte Auswahl der geeigneten Variablen denkbar.

Wenn die Eingangsvariablen festgelegt sind, werden für jede davon fahrerspezifisch die Fuzzy Sets erstellt. Dies geschieht dadurch, dass während der normalen Fahrt die Variable in den für das Manöver relevanten Szenarien beobachtet wird. Wenn genug Daten vorhanden sind, wird aus den beobachteten Werten eine Aufteilung des Wertebereichs der Variable in Fuzzy Sets vorgenommen, wobei die in [6] geforderten Kriterien Coverage und Semantic Soundness erfüllt sein müssen. Aus diesen Kriterien ergeben sich folgende Anforderungen:

- Jeder Wert im Wertebereich der Variable hat zu mindestens einem Fuzzy Set Zugehörigkeit größer als 0.
- Jeder Wert im Wertebereich der Variable hat nur zu einem Fuzzy Set Zugehörigkeit größer als 0.5.
- Der Wertebereich wird in 7 ± 2 Sets eingeteilt. Dieses Kriterium wird zum Zweck der Manöverprädiktion auf $4 - 7$ Sets modifiziert. Bei den in der Fahrermodellierung auftretenden Variablen wie etwa Geschwindigkeit (Abb. 1) ist eine Aufteilung in mehr als 7 Sets für eine sinnvolle semantische Interpretation in den meisten Fällen nicht geeignet.

Eine Einteilung, die diese Kriterien erfüllt, ist beispielhaft für die Variable „Geschwindigkeit im Stadtverkehr“ in Abb. 1 dargestellt.

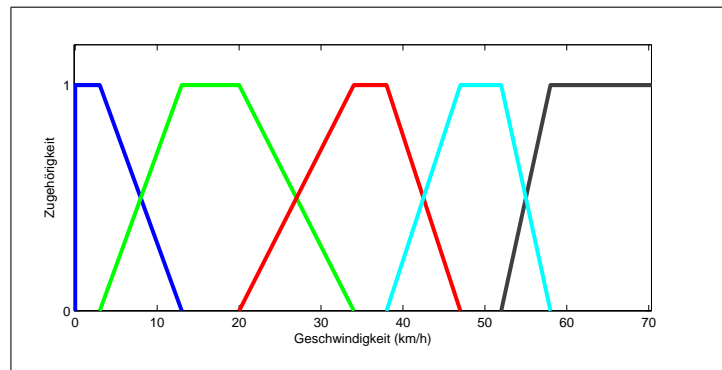


Abbildung 1: Fuzzy Sets für die Fuzzy Variable „Geschwindigkeit“

Nachdem alle Variablen in Fuzzy Variablen überführt sind, wird anhand von Beispielen die Regelbasis erstellt, die das Manöver beschreibt. In erster Instanz wird dazu eine Regelbasis erstellt, die aus der Kombination aller Fuzzy Sets der Eingabevariablen und der Identitätsfunktion als Fuzzy Set der Ausgangsvariable besteht. Für die Berechnung des Ausgabewerts des Fuzzy-Systems

wird die Standardkonjunktion $\min()$, die Mamdani-Inferenz [3] und die Min-of-Maximum-Methode als Defuzzifizierungsoperator verwendet. Anhand auftretender Beispielmanöver im Fahrbetrieb werden diejenigen Regeln, die in keinem Fall eine hohe Aktivierung aufweisen, aus der Regelbasis entfernt. Die übrigen Regeln durchlaufen anschließend für das Manöver relevante Fahrscenarien (im Falle des Abbiegeverhaltens etwa Stadtfahrten ohne Abbiegemanöver), um die Anzahl an falschen Aktivierungen jeder Regel zu bestimmen. Die endgültige Regelbasis besteht aus den Regeln mit hoher Effektivität, also jenen Regeln, die eine gute Voraussage des Manövers bei gleichzeitig geringer Falschalarmrate ermöglichen.

4 Anwendung

Die oben vorgestellte Methode wurde an einem exemplarischen Manöver analysiert. Als Datenbasis diente eine bei Volkswagen entstandene Datenbank [8], die eine Reihe von Messfahrten mehrerer Probanden auf einer festgelegten Strecke im Raum Braunschweig enthält. Die Datenbank beinhaltet neben unterschiedlichen Fahrzeug- und Sensordaten (einen Überblick gibt es in [7]) hochgenaue Karten- und Positionsdaten. Dies erlaubt zu jedem Zeitpunkt eine detaillierte Rekonstruktion der Fahrsituation. Es wurde als Beispiel das Manöver „Stopverhalten“ analysiert. Dabei wird versucht vorauszusagen, ob das Fahrzeug bei Anwesenheit eines Hindernisses (anderes Fahrzeug, Ampel, Abbiegung, Kreuzung) eine sehr niedrige Geschwindigkeit (5 km/h) unterschreiten wird. Dieses Beispiel wurde gewählt, da ein hoher Nutzen etwa für Kreuzungsassistenzsysteme zu erwarten ist.

Für jeden Fahrer wurden aus der Datenbank alle Sequenzen aus dem Stadtverkehr extrahiert, die positiven Beispiele identifiziert und die Werte der im Voraus bestimmten Eingangsvariablen berechnet. Die Variablen teilen sich auf in Fahrzeugvariablen

- Geschwindigkeit
- Fahrpedalwert
- Längsbeschleunigung

und Objektvariablen, getrennt für Fahrzeuge in der gleichen Fahrspur, Ampeln und Abbiegungen bzw. Kreuzungen.

- Abstand
- Zeitlücke
- Änderung der Zeitlücke

Die Variablen wurden fahrerspezifisch in Fuzzy Variablen überführt. In Abbildung 2 sind die Partitionierungen der Variable „Zeitlücke“ für zwei Fahrer zu




Abbildung 2: Fuzzy Sets für die Variable „Zeitlücke“ zweier Fahrer

sehen. Sie beschreibt die Zeit, die das Fahrzeug braucht, um die die aktuelle Position des vor ihm fahrenden Fahrzeugs zu erreichen. Aus der Abbildung ist ersichtlich, dass sie sich deutlich voneinander unterscheiden, der obere Fahrer bevorzugt kürzere Zeiten als der untere. Dieses Beispiel verdeutlicht die Wichtigkeit fahrerabhängiger Variablen, für die zwei Fahrer hat etwa der Begriff einer „großen Zeitlücke“ (in hellblau dargestellt) eine ganz andere Bedeutung. Es ist durchaus möglich, eine Einteilung für alle Fahrer vorzunehmen, doch haben dadurch die aus diesen generischen Variablen erzeugten Regeln für den einzelnen Fahrer keine semantisch sinnvolle Bedeutung mehr.

Um die Aussagekraft der Regeln zu erhöhen wurde die zusätzliche Variable „Regelzeit“ eingeführt, die einen Aspekt des zeitlichen Verlaufs eines Manövers modelliert. Sie ist in Abbildung 3 dargestellt. Die Variable gibt an, wie lange




Abbildung 3: Fuzzy Sets für die Variable „Regeldauer“

die aktuelle Regel den höchsten Aktivierungsgrad aller Regeln besitzt und dient der Unterscheidung zwischen Regeln, die über einen kurzen bis langen Zeitraum aktiv sind. Dadurch können Regeln, die in einem bestimmten zeitlichen Bereich hauptsächlich bei positiven Beispielen aktiv sind, in die Regelbasis aufgenommen werden, obwohl die Regel ohne dieser Variable meist bei negativen Beispielen eine hohe Aktivierung aufweist.

Anschließend wurden anhand der extrahierten Fahrdaten die Regeln gelernt. Die positiven Beispiele bestanden aus kurzen Zeitintervallen, beginnend vier Sekunden vor der Unterschreitung der Geschwindigkeit von 5 km/h bis zum Stillstand oder der erneuten Überschreitung dieser Grenze. Die negativen Beispiele waren alle Stadtfahrten mit Ausnahme der positiven Beispiele. Die so gelernte Regelbasis beschreibt das Stopverhalten des Fahrers.

Es hat sich gezeigt, dass bei der Manövervorhersage eine Schwäche der hier verwendeten Form von Fuzzy Logic auftreten kann. Da der Aktivierungsgrad einer Regel dem Minimum der beteiligten Fuzzy Variablen entspricht, kann eine einzelne wenig aktive Variable die Aktivierung der Regel verhindern. Dies tritt auf, wenn sich bei einer Variable dessen Wert über längere Zeit in dem Bereich zwischen zwei Sets befindet. Dies wird in Abbildung 4 deutlich. In dem rechten Bild ist die Partitionierung der Fuzzy Variable „Abstand“ zu sehen, links die Eingangswerte eines Stopmanövers. Bei dem Beispiel ist zu sehen, dass vor dem Stillstand der Abstand zu dem Vorderfahrzeug für einen längeren Zeitraum in dem Bereich zwischen den zwei Sets „Sehr gering“ und „Gering“ liegt. Dieses Manöver wird mit der gelernten Regelbasis voraussichtlich nicht richtig vorhergesagt werden. Eine mögliche Lösung des Problems ist die Erweiterung

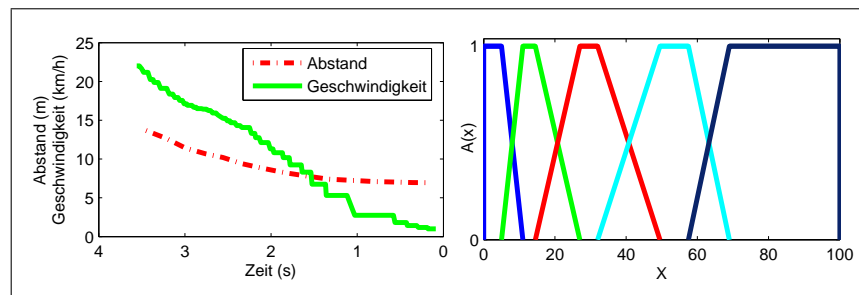


Abbildung 4: Beispielmanöver und Fuzzy Variable „Abstand“

der Regelbasis durch Regeln mit modifizierten Fuzz Sets. Eine neue Regel wird aus zwei Regeln erstellt, wenn folgende Kriterien erfüllt sind:

- Die zwei Regeln sind bis auf die Sets einer Variable identisch.
- Die beteiligten Sets dieser Variable sind benachbart.
- Die Summe beider Regeln besitzt einen hohen Effektivitätswert.

Sind diese Forderungen erfüllt, wird eine neue Regel erzeugt. Für die relevante Variable werden die entsprechenden Sets durch deren Kombination ersetzt. Für das Beispiel aus Abbildung 4 ist die Kombination das in Abbildung 5 rot dargestellte Set $SG + G$.

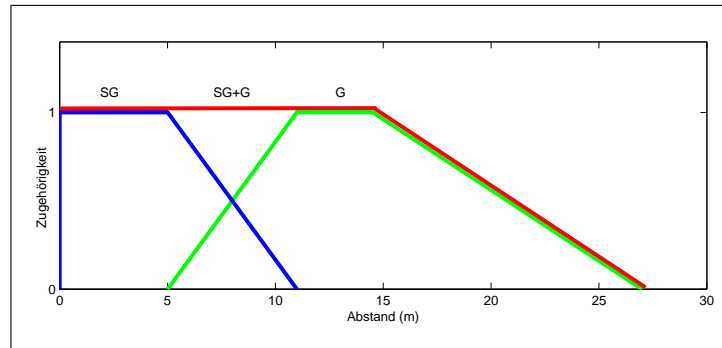


Abbildung 5: Kombination zweier Fuzzy Sets

5 Auswertung

Um die Güte des Verfahrens zu bestimmen bietet sich das Verfahren der Leave-One-Out-Kreuzvalidierung an. In diesem Verfahren werden die Fahrdaten in N Datensätze aufgeteilt. Anschließend erfolgen N Durchläufe, wobei jeweils einer der Datensätze aus der Trainingsmenge entfernt und zum Testen benutzt wird. Der mittlere Prädiktionsfehler aus allen Durchläufen liefert den Gesamtfehler. Die Trennung der Daten in Trainings- und Testmengen erlaubt eine Aussage über die Generalisierungsfähigkeit der gelernten Regeln.

Da jeder Proband die Strecke mehrmals an unterschiedlichen Tagen fuhr, wurde die Trennung der Daten in Datensätze einzelner Tage vorgenommen. Je nach Proband enthält die Datenbank 4 – 6 Fahrten, wobei bei jeder Fahrt durchschnittlich 10 Haltemanöver auftreten. Dem oben beschriebenen Verfahren folgend wurden jeweils die Daten eines Tages entfernt und die Regelbasis mit den Daten aus den restlichen Fahrten gelernt. Zur Bestimmung der Klassifikationsgüte bekam die Regelbasis daraufhin die herausgenommenen Daten vorgelegt. Sobald die Aktivierung die Schwelle von 0.7 überschritt, wurde die Situation als Stopmanöver klassifiziert. Alle Aktivierungen, bei denen der jeweils nächste Zeitschritt mit hoher Aktivierung unter der Grenze von 0.5 s lag, wurden zu einer Situation zusammengefasst. Für jede dieser Situationen wurde bestimmt, ob die Aktivierung innerhalb des oben definierten Zeitraums eines positiven Beispiels lag. War dies der Fall, galt das Beispiel als korrekt prädiziert, ansonsten handelte es sich um eine Fehlentscheidung. Um das unterschiedliche Stopverhalten der Fahrer zu betrachten wurden darüber hinaus für jeden Fahrer eine Regelbasis aus allen verfügbaren Fahrten erstellt und diese mit den Fahrten der anderen Fahrer ausgewertet. Die Differenz zwischen den Ergebnissen der eigenen und der fremden Fahrten gibt Aufschluss darüber, wie stark das Verhalten eines Fahrers von denen der anderen Personen abweicht.

Die Ergebnisse der Kreuzvalidierung und des Fahrervergleichs sind links in Abbildung 6 dargestellt. Die Detektionsraten sind im Falle der Kreuzvalidierung

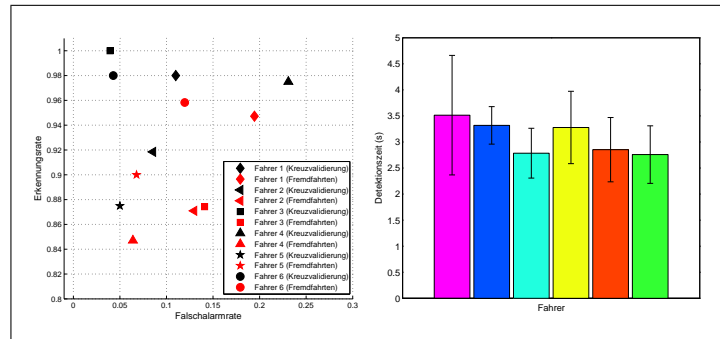


Abbildung 6: Ergebnisse

gen bei Fahrern 1,3,4 und 6 sehr hoch, was für eine gute Generalisierungsfähigkeit des Systems spricht. Die Ergebnisse von Fahrer 2 dagegen sind diesbezüglich deutlich schlechter. Genaue Untersuchungen haben ergeben, dass es sich bei den nicht erkannten Szenarien hauptsächlich um Haltemanöver an Kreuzungen handelte, die ohnehin selten und bei diesem Fahrer sehr ungleich auf die Fahrten verteilt auftraten. Eine größere Anzahl an Beispielmanövern würde voraussichtlich zu einer höheren Erkennungsrate führen.

Die Ergebnisse des Fahrervergleichs deuten auf ein unterschiedliches Stopverhalten der Fahrer hin. Bis auf einen Fahrer sind bei jedem Fahrer die Falschalarmraten bei Fremdfahrten höher als bei den eigenen Fahrten, teilweise sogar mehr als doppelt so hoch. Es ist auf Grund der Verteilungen der schwarzen (eigene Fahrten) und roten (Fremdfahrten) Markierungen zu sehen, dass im Allgemeinen die individuell gelernten Regeln das Fahrverhalten des jeweiligen Fahrers besser beschreiben als das Verhalten der weiteren Fahrer. Abbildung 2 und der Fahrervergleich zeigen, dass es sowohl bei dem Verhalten als auch in der Situationswahrnehmung deutliche Unterschiede zwischen den Fahrern gibt. Bei den in Abbildung 6 rechts dargestellten Detektionszeiten sind die Unterschiede zwischen den Fahrern weniger ausgeprägt. Die hohe Standardabweichung bei Fahrer 1 weist darauf hin, dass sich bei diesem Fahrer die Manöver stark voneinander unterscheiden. Die gleichzeitig hohe Erkennungsrate spricht für die Generalisierungsfähigkeit des hier vorgestellten Verfahrens.

Für eine optimale Auslegung von Assistenzsystemen sind diese Unterschiede zu berücksichtigen. Angenommen, es wird ein Ampelassistenzsystem entwickelt, dass bei Nichtbeachtung einer roten Ampel eine Fahrerwarnung ausgibt. Auch wenn ein generisches System gut funktioniert, kann die Prädiktion des Stopverhaltens des einzelnen Fahrers den in Abbildung 6 gezeigten Ergebnissen nach eventuelle Falschalarme reduzieren und das Assistenzsystem somit für den Kunden noch attraktiver machen.

6 Zusammenfassung und Ausblick

Die Ergebnisse zeigen, dass die fahrerspezifische Prädiktion von Fahrmanövern sinnvoll und für die Auslegung von Assistenzsystemen relevant ist. Das System ist in der Lage, selbstständig das Verhalten des Fahrers bei Haltevorgängen zu analysieren und neue Stopmanöver korrekt vorherzusagen, sofern diese nicht zu stark von dem bisherigen Verhalten abweichen. Darüber hinaus bildet das Modell das individuelle Verhalten des Fahrers ab, wie die Abweichungen zwischen den Ergebnissen der Kreuzvalidierung und der Fremdfahrten belegen. Da während des Lernens kein menschliches Eingreifen notwendig ist, kann es in ein beliebiges mit ausreichender Sensorik ausgestattetes Fahrzeug integriert und nach einer angemessenen Lernphase zur Prädiktion der entsprechenden Manöver genutzt werden. Die Modellierung des Verhaltens als eine Menge von Regeln garantiert die Nachvollziehbarkeit des Modellverhaltens, was für die Validierung von großer Wichtigkeit ist.

Es sind jedoch noch weitere Schritte notwendig, um diese Ergebnisse zu untermauern. Erstens sind die Ergebnisse der Kreuzvalidierung noch nicht in jedem Fall zufriedenstellend, die Manövervorhersage muss also noch verbessert werden. Zweitens muss das Verfahren auf die Vorhersage zunehmend komplexerer Fahrmanöver ausgeweitet werden. Drittens ist die fahreradaptive Parametrierung eines Assistenz- oder Sicherheitssystems, beispielsweise einer Notbremsfunktion, durchzuführen. Es ist zu untersuchen, ob mit Hilfe des Fahrermodells eine autonome Vollbremsung früher als mit dem aktuell vorhandenen System durchgeführt werden kann, ohne dabei die Auslösesicherheit zu beeinträchtigen. Eine frühere Auslösung führt zu einem größeren Geschwindigkeitabbau und somit einem höheren Nutzen der Funktion.

Literatur

- [1] C. Blaschke, J. Schmitt, and B. Färber. Fahrmanöver-Prädiktion über CAN-Bus Daten. In *Fahrer im 21. Jahrhundert -Human Machine Interface*, pages 165–177. VDI, 2007.
- [2] T. Kumagai, Y. Sakaguchi, M. Okuwa, and M. Akamatsu. Prediction of Driving Behavior through Probabilistic Inference. In *International Conference on Engineering Applications of Neural Networks*, volume 8, pages 8–10, 2003.
- [3] E. H. Mamdani and Others. Application of fuzzy algorithms for control of simple dynamic plant. *Proceedings of IEEE*, 121(12):1585–1588, 1974.
- [4] J. A. Michon. A critical view of driver behaviour models: What do we know, what should we do? In L. Evans & R. C. Schwing, editor, *Human Behaviour and Traffic Safety*, pages 485–520. Plenum Press, 1985.
- [5] N. Oliver and A. P. Pentland. Graphical Models for Driver Behavior Recognition in a SmartCar. In *IEEE Intl. Conference on Intelligent Vehicles*, pages 7–12, 2000.

- [6] W. Pedrycz and F. Gomide. *Fuzzy Systems Engineering: Toward Human-Centric Computing*. Wiley-IEEE Press, 2007.
- [7] R. Suikat, J. Rataj, H. Schäfer, and R. Rollke. ViewCar - den Fahrer verstehen. In *Optische Technologien in der Fahrzeugtechnik*. VDI Verlag, 2003.
- [8] A. Tenzer. Die Fahrerleistungsdatenbank der Volkswagen AG als Werkzeug zur Beobachtung von Fahrerverhalten. In *21. VW/VDI-Gemeinschaftstagung „Integrierte Sicherheit und Fahrerassistenzsysteme“*, 2004.
- [9] L. Zadeh. Fuzzy sets. *Information and Control*, 8(3):338–353, 1965.