

Fahrermodellierung im Kontext kognitiver Automobile

Driver Modelling within the Context of Cognitive Automobiles

Barbara Deml, Hendrik Neumann, André Müller und Hans Joachim Wünsche

In dieser Arbeit werden vier Ansätze zur Fahrermodellierung vorgestellt und an einem Beispiel gezeigt, dass sich damit sowohl individuelle Unterschiede im Lenkverhalten als auch strategische Fahraufgaben abbilden lassen. Abschließend wird diskutiert, wie sich dies für die Entwicklung autonomer Fahrzeuge nutzen lässt.

Within this work four approaches to driver modelling are presented; by relying on one example it is shown that this procedure is suited to model individual steering profiles as well as the execution of a strategic driving task. Finally, it is discussed why this is also useful within the context of autonomous cars.

Schlagwörter: Kognitive Fahrermodellierung, Pelops, Cosmodrive, QN-MHP, ACT-R

Keywords: Cognitive driver modelling, Pelops, Cosmodrive, QN-MHP, ACT-R

1 Einleitung

Von einem kognitiven Automobil wird erwartet, dass es sich selbst und seine Umwelt wahrnehmen kann. Darüber hinaus sollte es auch in der Lage sein, eigenständig Wissen zu erwerben und zu strukturieren, so dass es schließlich zu individuellem und kooperativem Verkehrsverhalten fähig ist [1]. Während dies für technische Systeme eine große Herausforderung darstellt, handelt es sich für Menschen in der Regel um eine alltägliche Aufgabe. Aus dem Grund ist es naheliegend, dass eine formale Beschreibung des menschlichen Verhaltens, in Form von rechnergestützten Fahrermodellen, auch wertvolle Impulse für die Entwicklung kognitiver Automobile setzen kann. Im Folgenden werden zunächst einige solcher Modellierungsansätze vorgestellt (Abschnitt 2). Da vor dem Hintergrund der Arbeit insbesondere eine Herangehensweise viel versprechend erscheint, soll diese im Rahmen zweier empirischer Studien näher betrachtet werden (Abschnitt 3). Die Ergebnisse der Untersuchung sowie ihre Bedeutung für die Entwicklung kognitiver Automobile werden abschließend diskutiert (Abschnitt 4).

2 Fahrermodellierung

In der Literatur existieren zahlreiche Fahrermodelle. Berücksichtigt man allerdings lediglich Modelle, die in der

Lage sind, das Fahrverhalten in Echtzeit zu präzisieren, so reduziert sich die Anzahl der Arbeiten erheblich. Vor dem Hintergrund der Fragestellung werden aber noch eine Reihe weiterer Anforderungen gestellt: Es sind nur Modellierungsansätze interessant, die sowohl perzeptuelle als auch kognitive und motorische Prozesse des Fahrers abbilden können. Diese Forderung, den Wahrnehmungs-Kognitions-Handlungszyklus zu schließen, wird auch als Embodied-Cognition [2] bezeichnet. In dem Zusammenhang ist es auch wünschenswert, dass das Modell in der Lage ist, mit Artefakten der Umwelt zu interagieren, also an ein Fahrzeug oder einen Simulator gekoppelt werden kann. Weiterhin sollte die Fahraufgabe möglichst ganzheitlich darstellbar sein. Orientiert man sich an dem Drei-Ebenen-Modell der Fahrzeugführung [3], so muss der Ansatz das Potenzial haben, wesentliche Aspekte der Stabilisierung (operative Ebene), der Bahnführung (taktische Ebene) sowie der Routenplanung (strategische Ebene) zu thematisieren.

Von einem ingenieurwissenschaftlichen Standpunkt aus ist es häufig ausreichend, ein bestimmtes, empirisch beobachtbares Verhalten formal zu beschreiben. Für kognitionswissenschaftliche Forschungsfragen ist es hingegen mindestens genauso wichtig, die kognitiven Prozesse, die zu einer Verhaltensausprägung führen, zu verstehen. Aus dem Grund sollte das Modell möglichst detailliert erklären können, warum ein bestimmtes Fahrverhalten resultiert. Ein wei-

teres Kriterium besteht schließlich darin, dass der Ansatz praktikabel ist und sich das Fahrermodell mit vertretbarem Aufwand erweitern oder anpassen lässt.

Im Folgenden werden exemplarisch vier solcher Fahrermodelle vorgestellt, wobei grundsätzlich zwischen *aufgabenspezifischen* (Abschnitt 2.1) und *generischen* Ansätzen (Abschnitt 2.2) unterschieden wird. Um die Modelle vergleichen zu können, erfolgt schließlich eine Bewertung hinsichtlich der oben genannten Kriterien (Abschnitt 2.3): Verhaltensprädiktion, Embodied-Cognition, Umweltartefakte, Aufgabenebenen, Prozessmodellierung, Detaillierungsgrad und Praktikabilität.

2.1 Aufgabenspezifische Ansätze

Aufgabenspezifische Ansätze wurden einzig vor dem Hintergrund der Fahrermodellierung entwickelt und stellen keine „Unified Theories of Cognition“ dar. So erheben *Pelops* (Abschnitt 2.1.1) und *Cosmodrive* (Abschnitt 2.1.2) nicht den Anspruch, Verhalten in einem anderen Kontext als Autofahren zu modellieren.

2.1.1 Pelops

Die Abkürzung *Pelops* steht für „Programmsystem zur Entwicklung längsdynamischer, mikroskopischer Verkehrsprozesse in systemrelevanter Umgebung“ [4]. Eine Stärke des Ansatzes ist sicherlich, dass Wechselwirkungen zwischen Fahrer, Fahrzeug und Strecke ganzheitlich abgebildet werden. Das Fahrermodell gliedert sich dabei in ein Verhaltens- und ein Handlungsmodell (Bild 1):

Das *Verhaltensmodell* besteht aus einem Folge- und einem Spurwechselmodell. Das *Folgemodell* beschreibt den Verkehr auf einer einspurigen Richtungsfahrbahn, auf der es keine Möglichkeit zum Spurwechsel gibt. Es unterscheidet vier Situationen: unbeeinflusstes Fahren, Annähern, Folgen und Bremsen. Die Situationswahl hängt dabei nicht nur von der Differenzgeschwindigkeit und dem Abstand zu einem vorausfahrenden Fahrzeug ab, sondern berücksichtigt auch fahrindividuelle Parameter (z. B. Schätzvermögen). Für jede mögliche Situation sind entsprechende Verhaltensregeln in Form von Algorithmen hinterlegt, welche die Reaktion des Modellfahrers bestimmen. Die Datenbasis dafür bildet ein validierter Satz von mehreren hundert Standardfahrertypen. Das *Spurwechselmodell* deckt alle Verkehrssituationen ab, die auf mehrspurigen Straßen und im innerstädtischen Verkehr auftreten. Der Grundgedanke ist, dass der Modellfahrer die Zufriedenheit auf der eigenen Spur mit der zu erwartenden Zufriedenheit auf den Nachbarspuren vergleicht. Dabei wird schließlich die Spur mit dem höchsten

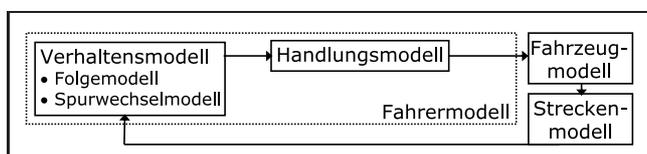


Bild 1: Das Pelops-Fahrermodell [4].

Zufriedenheitswert gewählt und gegebenenfalls ein Spurwechsel eingeleitet. Mit dem Verhaltensmodell wird eine lokale Fahrstrategie definiert, die vom *Handlungsmodell* in fahrzeugseitige Stellgrößen, wie Lenkbewegungen, umgesetzt wird.

2.1.2 Cosmodrive

Die Abkürzung *Cosmodrive* steht für „Cognitive Simulation Model of the Driver“ [5]. Während bei Pelops vor allem feste Verhaltensregeln hinterlegt sind, bietet dieser Ansatz mehr Möglichkeit, um kognitive Prozesse zu simulieren. Dabei werden zwei Arten der Informationsverarbeitung unterschieden: Hier ist zum einen das Langzeitgedächtnis zu nennen, in dem das Wissen eines Autofahrers repräsentiert ist (z. B. Rechtsfahrgebot). Zum anderen existiert ein Arbeitsgedächtnis, das auch als *taktisches Modul* bezeichnet wird. Hier werden das Wissen aus dem Langzeitgedächtnis und aktuelle Wahrnehmungsinformationen zu einem mentalen Modell „verrechnet“, das die Grundlage für das Fahrverhalten darstellt. Weiterhin sind ein *strategisches Modul* (z. B. Routenplanung) und ein *operatives Modul* (z. B. Lenken, Geschwindigkeitswahl) vorgesehen (Bild 2).

Die Schnittstelle zwischen diesen Modulen und der Verkehrsumwelt bilden auf der einen Seite das *Wahrnehmungsmodul* und auf der anderen Seite das *Ausführungsmodul*. Darüber hinaus gibt es ein *Koordinationsmodul* zur Abstimmung kognitiver Prozesse sowie ein *Notfallmodul*, das strategische oder taktische Prozesse gegebenenfalls blockieren kann.

Der Cosmodrive-Ansatz ist flexibler als Pelops, da keine konkreten Verhaltensmuster (z. B. Folgen, Spurwechsel) implementiert sind. Im Mittelpunkt steht die Möglichkeit, beliebige mentale Repräsentationen mittels so genannter „Driving-Frames“ in der Programmiersprache SmallTalk zu modellieren.

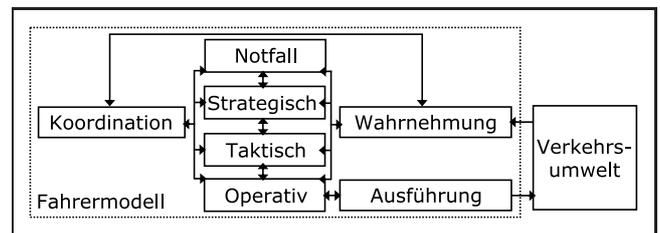


Bild 2: Das Cosmodrive-Fahrermodell [5].

2.2 Generische Ansätze

Anders als aufgabenspezifische Herangehensweisen erheben generische Ansätze den Anspruch, verschiedene Aspekte menschlichen Verhaltens zu modellieren. Folglich wird eine kognitive Architektur, wie *QN-MHP* (Abschnitt 2.2.1) oder *ACT-R* (Abschnitt 2.2.2) benötigt, die einerseits eine Programmierumgebung und andererseits eine Theorie menschlicher Informationsverarbeitungsprozesse darstellt.

2.2.1 QN-MHP

Die Abkürzung *QN-MHP* steht für „Queueing Network-Model Human Processor“ [6]. In dieser Architektur werden menschliche Informationsverarbeitungsprozesse mit einer Metapher aus der Informatik beschrieben und strikt auf neurobiologische Prozesse übertragen (Bild 3):

Es wird ein *perzeptuelles*, *kognitives* und *motorisches Subnetzwerk* unterschieden, das jeweils aus mehreren Servern besteht. Zu einem Server werden dabei Gehirnregionen mit ähnlichen Funktionen zusammengefasst, die eine bestimmte Dienstleistung anbieten (z. B. Bearbeitung visueller Clients). Die neuronalen Pfade entsprechen den Routen, durch welche die Clients von Server zu Server im Netzwerk fließen. Während die Informationsströme mathematisch modelliert werden, ist die Verarbeitungslogik innerhalb der Server symbolisch repräsentiert. QN-MHP lässt sich in jede Simulationssoftware (z. B. ProModel) implementieren, mit der sich komplexe Prozessabläufe visualisieren lassen.

Mit der Architektur wurden bereits unterschiedliche Aufgaben modelliert, so auch die Spurhaltung mit konstanter Geschwindigkeit im Rahmen einer Fahraufgabe. Das Fahrermodell wurde dabei auch in eine Fahrsimulation eingebunden:

Die Eingabeparameter für das Lenkmodell stellen die Längs- und Querposition des Fahrzeugs sowie die Straßenkrümmung dar. Um das Hauptziel, die Spurhaltung, zu erreichen, werden parallel drei untergeordnete Ziele verfolgt, nämlich die Kodierung der Fahrzeugposition, die Wahl der Lenkstrategie sowie die Anweisung der Lenkhandlung. Bei den Ausgaben des Modells handelt es sich um Koordinaten, die zum einen die Handposition am Lenkrad und zum anderen die Fixationspunkte des Auges angeben.

Das Fahrermodell kann auch Nebenaufgaben bearbeiten und zum Beispiel Ziele auf einer Landkarte suchen. Die Lenk- und Nebenaufgabe werden dann als zwei Informationsströme im Netzwerk betrachtet, die simultan verfolgt werden. Bei Serverkonflikten (z. B. unterschiedliche Anweisungen an die Augen), wird die Nebenaufgabe aller-

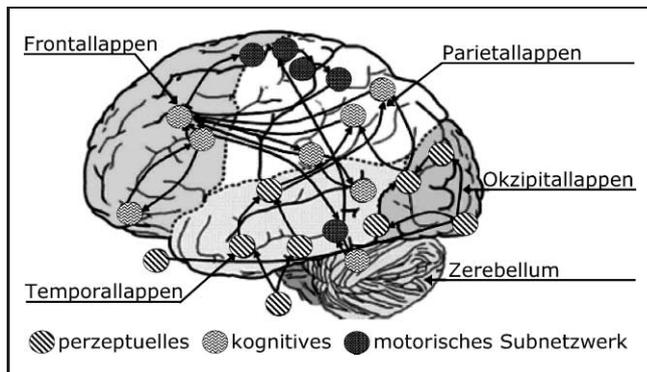


Bild 3: Die kognitive Architektur QN-MHP [6]. Jeder Kreis stellt einen Server dar; Pfeile stehen für neuronale Pfade.

dings nur dann bearbeitet, wenn die Time-to-Line-Crossing mehr als vier Sekunden beträgt.

Festzuhalten ist, dass mit dieser Netzwerkanalogie eine recht genaue Modellierung kognitiver Prozesse gelingt; so lässt sich der Grad der Serverauslastung zum Beispiel unmittelbar als mentale Beanspruchung interpretieren. Ebenso erlaubt der Ansatz die Abbildung individueller Unterschiede (z. B. Altersunterschiede zwischen Fahrern über die kognitive Verarbeitungsgeschwindigkeit).

2.2.2 ACT-R

Die Abkürzung *ACT-R* steht für „Adaptive Control of Thought-Rational“ [7]; es handelt sich um ein modular angelegtes Produktionensystem (Bild 4):

Die Schnittstelle zur realen Welt bildet das *visuelle* und *auditive* sowie das *sprachliche* und *motorische* Modul. Darüber hinaus sind zwei Gedächtnismodule realisiert: Das Faktenwissen (z. B. Rechtsfahrgebot) ist im *deklarativen Gedächtnis* gespeichert; das Handlungswissen (z. B. schneller fahren durch Gaspedalbetätigung) ist im *prozeduralen Gedächtnis* hinterlegt. Das Wissen muss nach einer bestimmten Syntax, die auf der Programmiersprache LISP basiert, definiert werden.

Jedes Modul – mit Ausnahme des prozeduralen Gedächtnisses – verfügt über einen *Puffer*, der die Schnittstelle zum System darstellt. Obwohl viele Prozesse parallel ablaufen, kann jeder Puffer immer nur eine Wissensseinheit aufnehmen, die den aktuellen Modulzustand repräsentiert. Dieser Flaschenhals wird der menschlichen Ressourcenbegrenzung bei der zentral-sensorischen Verarbeitung gerecht.

Die Interaktion mit den Puffern findet über Produktionsregeln statt, die im prozeduralen Gedächtnis implementiert sind und die jeweils aus einem Bedingungs- und einem Handlungsteil bestehen. Passt eine Produktionsregel zu den Pufferinhalten, so wird die entsprechende Regel gefeuert und damit eine Handlung initiiert. Auch hier besteht eine theoretisch sinnvolle Begrenzung: Zu jedem Zeitpunkt kann nur eine *Produktionsausführung* initiiert werden. Auch wenn immer nur eine Produktion gefeuert wird, können trotzdem gleichzeitig mehrere Produktionsregeln zu den Pufferinhalten passen. Aus dem Grund verfügt

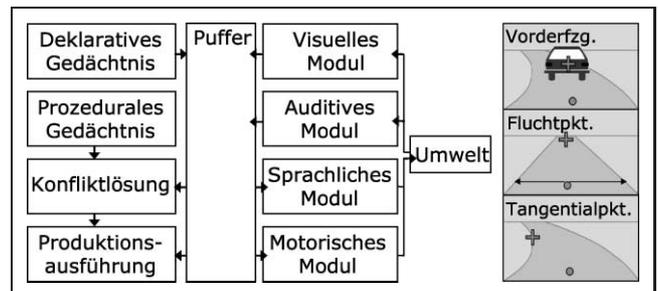


Bild 4: links. Die kognitive Architektur ACT-R [7]; rechts. Das Lenkverhalten des Fahrermodells [8] basiert auf einem Nahpunkt (Kreis) und einem Fernpunkt (Kreuz). Ist kein Vorderfahrzeug vorhanden, so liegt der Fernpunkt im Fluchtpunkt bzw. bei Kurven im Tangentialpunkt der Straße.

ACT-R über sub-symbolische Mechanismen zur *Konfliktlösung*. So entscheidet eine Kosten-Nutzen-Funktion, welche der zutreffenden Regeln ausgeführt wird. Ebenso bestimmen der Kontext sowie die Nutzungshistorie, ob und wie schnell Wissen aus dem deklarativen Gedächtnis abrufbar ist. Außerdem ist ein wahrscheinlichkeitsbasierter Lernmechanismus implementiert.

ACT-R wurde bereits für sehr unterschiedliche Fragestellungen eingesetzt; ein Fahrermodell wurde von Salvucci [8] vorgeschlagen. Simuliert wird ein Autofahrer, der sich auf einer mehrspurigen Autobahn mit mittlerer Verkehrsdichte befindet. Wie das Pelops-Modell [4] ist ein Folge- und Spurwechselverhalten implementiert; darüber hinaus kann der Modellfahrer, wie das QN-MHP-Modell [6], auch Nebenaufgaben bearbeiten:

Bei der Quer- und Längsführung orientiert sich der Ansatz am menschlichen Verhalten. Demnach benötigen Menschen für eine stabile Querführung zwei Punkte, einen Fern- und einen Nahpunkt (Bild 4 rechts). Der *Fernpunkt* befindet sich mittig auf dem Heck eines Vorderfahrzeugs oder, falls kein Vorderfahrzeug vorhanden ist, fällt der Punkt mit dem Flucht- oder dem Tangentialpunkt der Straße zusammen. Darüber hinaus erfordern sichere Lenkbewegungen noch die Information von einem *Nahpunkt*, der ungefähr fünf Meter vor dem Fahrzeug liegt. Das Fahrermodell richtet seine Aufmerksamkeit zunächst auf den Nah- und dann auf den Fernpunkt, registriert jeweils den visuellen Winkel und berechnet die Abweichung gegenüber dem letzten Zyklus. Aus der wahrgenommenen Differenz erfolgt dann PI-geregelte eine inkrementelle Anpassung des Lenkwinkels, so dass beide Punkte stabil sind und das Fahrzeug mittig in der Spur geführt wird. Zur Längsführung registriert das Salvucci-Modell die Zeitlücke zum Vorderfahrzeug und vergleicht diese ebenfalls mit dem Wert aus dem vorangegangenen Berechnungszyklus. Der Modellfahrer versucht dabei nicht nur möglichst konstant zu folgen, sondern beschleunigt oder verzögert auch, um eine bestimmte Wunschzeitlücke zu realisieren.

Um Fremdverkehr zu berücksichtigen, richtet das Modell seine Aufmerksamkeit auch auf die linke und rechte Spur des vorderen und rückwärtigen Verkehrsraumes. Ist dort ein Fahrzeug vorhanden, so wird dessen Spur, Richtung und Abstand im Gedächtnis gespeichert. Auf dieser Basis werden dann taktische Entscheidungen getroffen und so zum Beispiel Spurwechsel initiiert, indem Nah- und Fernpunkt auf die Zielspur verlagert werden.

2.3 Zusammenfassende Bewertung

Jeder Ansatz kann auf eine über zehnjährige Forschungsaktivität zurückblicken und jedes Modell ist in der Lage, empirisch valide *Verhaltensprädiktionen* zu machen. Darüber hinaus folgen alle Ansätze dem *Embodied-Cognition-Paradigma* [2], alle können mit *Umweltartefakten*, also mit einem Fahrzeug oder einer Simulation, interagieren und alle haben prinzipiell das Potenzial, die drei *Aufgabenebenen* der Fahrzeugführung abzubilden. Nicht zuletzt deshalb sind

auch alle Herangehensweisen als elaboriert zu bezeichnen. Dennoch werden sie den eingangs gestellten Anforderungen unterschiedlich gut gerecht:

Im Gegensatz zu den anderen Ansätzen wird durch Pelops das Fahrverhalten zwar beschrieben, es wird aber kaum der Versuch unternommen, Verhaltensprozesse abzubilden. So wird nicht modelliert, wie inter-individuelle Unterschiede zustande kommen, sondern anstelle dessen auf empirisch gewonnene Datensätze verschiedener Fahrertypen zurückgegriffen. Wünschenswert wäre demgegenüber ein anderer Modellierungsansatz: Möchte man zum Beispiel das Verhalten eines älteren Autofahrers darstellen, so könnte man berücksichtigen, dass sich die kognitive Verarbeitungsgeschwindigkeit im Alter verlangsamt oder die Akkomodationsbreite des Sehapparates reduziert. Anstelle auf Messungen zurückzugreifen, würde das entsprechende Verhalten dann aus einer Modellierung der Informationsverarbeitungsprozesse resultieren. Einschränkend ist aber zu erwähnen, dass bislang kein Ansatz eine vollständige *Prozessmodellierung* leistet. So liegt der Fokus in der Regel auf zentral gesteuerten, höheren kognitiven Prozessen, während stimulusgetriebene Wahrnehmungsprozesse meist kaum modellierbar sind.

Darüber hinaus bestehen beträchtliche Unterschiede hinsichtlich des *Detaillierungsgrades*: QN-MHP und ACT-R ermöglichen eine sehr hohe zeitliche Auflösung, so bildet ACT-R Verhaltensregeln in 50-Millisekunden-Schritten ab. Eine solche Genauigkeit wird weder durch Pelops noch durch Cosmodrive erreicht.

Festzuhalten ist, dass von den vier Modellen nur die beiden generischen Ansätze eine Prozessmodellierung mit ausreichend hoher Genauigkeit erlauben. Aus dem Grund sollen nur diese Herangehensweisen hinsichtlich ihrer *Praktikabilität* gegenübergestellt werden: Während QN-MHP maßgeblich an der University of Michigan entwickelt wird, ist ACT-R wesentlich weiter verbreitet. Dies hat zum einen zur Folge, dass die Architektur beständig um weitere Module (z. B. Multitasking) erweitert wird; zum anderen existieren bereits eine Vielzahl von Modellen (z. B. visuelle Suche), die zum Teil frei verfügbar sind und für eigene Aufgabenstellungen angepasst werden können. Obwohl die Einarbeitung in ACT-R relativ zeitaufwändig ist, scheint dieser Ansatz daher insgesamt mehr Potenzial zu besitzen und soll hier weiterverfolgt werden.

3 Empirische Evaluation

Unabhängig davon, welches Fahrermodell betrachtet wird, liegt die Herausforderung darin, dass die Modellaussagen mit dem Verhalten „realer“ Fahrer übereinstimmen. Da Autofahren eine relativ komplexe Tätigkeit darstellt, lässt sich eine solche Übereinstimmung nicht auf einen einzigen Indikator reduzieren. Aus dem Grund sollen im Folgenden exemplarisch jeweils ein Aspekt der *operativen Ebene* (Abschnitt 3.1) und der *strategischen Ebene der Fahrzeugführung* (Abschnitt 3.2) aufgegriffen werden.

3.1 Operative Ebene der Fahrzeugführung

Insbesondere für die Spurhaltegüte werden in der Literatur eine Reihe von Maßen unterschieden, die sich entweder auf die Position des Fahrzeugs innerhalb der Spur oder auf das Lenkverhalten des Fahrers beziehen. Große Unterschiede zwischen verschiedenen Fahrern sind dabei vor allem beim Lenkverhalten zu beobachten [10]. Da die Fahrermodellierung insbesondere in der Lage sein sollte, diese individuellen Unterschiede abzubilden, wird hier das Maß *Nulldurchgang des Lenkwinkels* N_L genauer betrachtet. Dabei wird ausgewertet, wie oft das Lenkrad über die Geradeausstellung hinweg bewegt wird und der aufgezeichnete Lenkwinkel sein Vorzeichen ändert. Im Mittelpunkt steht damit die Häufigkeit korrektiver Lenkbewegungen, die sich vor allem auf geraden Streckenabschnitten aussagekräftig interpretieren lassen.

Um zu prüfen, ob das Fahrermodell tatsächlich menschliches Autofahren abbildet, wurde eine Evaluationsstudie durchgeführt, deren Ablauf (Abschnitt 3.1.1), Hypothese (Abschnitt 3.1.2) und Ergebnisse (Abschnitt 3.1.3) im Folgenden näher beschrieben werden.

3.1.1 Versuchsablauf

Als Versuchsstrecke wurde ein etwa zehn Kilometer langer, relativ gerader Autobahnabschnitt auf der A8 (Auffahrt 92, Abfahrt 94) gewählt. In einer Bedingung wurde der Abschnitt real von menschlichen Fahrern abgefahren; in der anderen Bedingung wurde die Strecke anhand ihrer GPS-Daten in einer Simulationsumgebung (Abschnitt 4) abgebildet und durch das Fahrermodell [8] befahren.

Da im Rahmen der Arbeit vor allem das Lenkverhalten untersucht werden soll, wurden weitere Parameter, die sich auf die Längsführung des Fahrzeugs beziehen, konstant gehalten: Die Probanden wurden instruiert, Adaptive-Cruise-Control zu aktivieren und mit einer konstanten Geschwindigkeit von 90 km/h auf der rechten Spur zu fahren. Für das Fahrermodell wurden die gleichen Einstellungen vorgenommen.

Trotz der hohen Vergleichbarkeit ist zu erwarten, dass verschiedene Fahrer ihr Lenkverhalten unterschiedlich häufig korrigieren [10]. Aus dem Grund wurde bei der Auswertung nicht über eine große Stichprobe aggregiert, sondern eine Einzelfallanalyse vorgenommen. Ebenso wurden nicht mehrere Simulationsdurchgänge des Fahrermodells zusammengefasst, sondern lediglich zwei Modellvarianten näher betrachtet. Die Auswertung der Ergebnisse erfolgt deshalb auch deskriptiv und nicht durch inferenzstatistische Methoden. Da beide Varianten theoriegeleitet erstellt wurden, soll zunächst das Fahrermodell näher beschrieben werden.

3.1.2 Hypothese

Dem Lenkmodell liegt folgende Überlegung zugrunde (ausführlichere Beschreibung siehe [9]): Das Fahrermodell fixiert einen bestimmten Zielpunkt und registriert den Winkel θ zwischen diesem und der eigenen Fahrzeugposition.

Dabei wählt es den Lenkwinkel φ so, dass θ möglichst klein wird. Zur formalen Beschreibung des Verhaltens schlagen [9] einen PI-Regler vor, wobei die Konstanten k_p und k_I zur Skalierung des proportionalen beziehungsweise integralen Anteils dienen:

$$\varphi = k_p \theta + k_I \int \theta dt \quad \text{bzw.} \quad \dot{\varphi} = k_p \dot{\theta} + k_I \theta \quad (1)$$

Wie die rechte, abgeleitete Gleichung (1) zeigt, versucht der Modellfahrer nicht nur den Zielpunkt zu stabilisieren (erster Term), sondern ihn gleichzeitig möglichst nahe Null zu halten (zweiter Term). Nach [8] nutzen menschliche Autofahrer aber nicht nur die Wahrnehmungsinformation eines Zielpunktes, sondern sie benötigen zwei Punkte: einen Fernpunkt θ_{fern} , der hier eine Zeitlücke von maximal vier Sekunden in Fahrtrichtung aufweist, und einen Nahpunkt θ_{nah} , der ungefähr fünf Meter mittig vor dem Fahrzeug liegt (Abschnitt 2.2). Aus dem Grund erscheint folgende Erweiterung sinnvoll:

$$\dot{\varphi} = k_{fern} \dot{\theta}_{fern} + k_{nah} \dot{\theta}_{nah} + k_I \theta_{nah} \quad (2)$$

Die erweiterte Gleichung (2) berücksichtigt zwei proportionale Komponenten, wobei der erste Term die Abweichung zum Fernpunkt $\dot{\theta}_{fern}$ und der zweite Term die Abweichung zum Nahpunkt $\dot{\theta}_{nah}$ darstellt; die Konstanten k_{fern} und k_{nah} dienen der Skalierung.

Um das Fahrzeug nicht nur in die gewünschte Richtung zu bewegen, sondern gleichzeitig möglichst mittig auf der Spur zu halten, ist die visuelle Richtungsinformation zum Nahpunkt θ_{nah} hilfreich; diese wird durch die integrale Komponente berücksichtigt. Festzuhalten ist, dass das Modell drei Ziele verfolgt, nämlich den Fernpunkt ($\dot{\theta}_{fern} \approx 0$) und den Nahpunkt ($\dot{\theta}_{nah} \approx 0$) stabil zu halten sowie das Fahrzeug mittig ($\theta_{nah} \approx 0$) zu führen.

Bedenkt man weiterhin, dass kognitive Prozesse diskret – in 50-Millisekunden-Schritten [7] – vollzogen werden, so schlagen [9] eine zeitdiskrete Schreibweise des Reglers vor. Dabei wird angenommen, dass der Modellfahrer seine Aufmerksamkeit regelmäßig auf den Nah- und den Fernpunkt richtet und die Abweichung zwischen zwei Zeitpunkten registriert:

$$\frac{d\theta}{dt} = k_{fern} \frac{d\theta_{fern}}{dt} + k_{nah} \frac{d\theta_{nah}}{dt} + k_I \theta_{nah} \quad (3)$$

$$\frac{\Delta\theta}{\Delta t} = k_{fern} \frac{\Delta\theta_{fern}}{\Delta t} + k_{nah} \frac{\Delta\theta_{nah}}{\Delta t} + k_I \theta_{nah} \quad (4)$$

$$\Delta\theta = k_{fern} \Delta\theta_{fern} + k_{nah} \Delta\theta_{nah} + k_I \theta_{nah} \Delta t \quad (5)$$

Ausgehend von diesem allgemeinen Lenkmodell (5) soll nun gezeigt werden, dass sich hiermit auch individuelle Unterschiede abbilden lassen. Ein Fahrer, der sein Lenkverhalten sehr häufig korrigiert, dürfte vor allem das Ziel verfolgen, sein Fahrzeug besonders mittig zu führen. Aus dem Grund ist folgende Hypothese plausibel: *Wird die Konstante k_I erhöht, so erhöht sich auch die Anzahl von Nulldurchgängen im Lenkwinkel N_L :*

$$k_{I1} > k_{I2} \implies N_{L1} > N_{L2} \quad (6)$$

Im Rahmen der Untersuchung wurden zwei Modellvarianten gegenübergestellt, wobei die ersten beiden Summanden (5) jeweils gleich gewichtet wurden ($k_{fern1} = k_{fern2} = 20$; $k_{nah1} = k_{nah2} = 10$) und lediglich der Einfluss des letzten Summanden systematisch variiert wurde ($k_{I1} = 6$; $k_{I2} = 3$). Dabei wird angenommen, dass der erste Modellfahrer „unruhiger“ fährt und mehr Nulldurchgänge im Lenkwinkel zu beobachten sind, wenn der gleiche Streckenabschnitt zurückgelegt wird.

3.1.3 Ergebnisse

Zunächst einmal ist festzuhalten, dass das Fahrermodell die simulierte Strecke problemlos bewältigen konnte. Zur besseren Vergleichbarkeit wird sich die empirische Auswertung allerdings nur auf eine Fahrt von zwei Minuten beschränken, in der Modell und Mensch jeweils den gleichen Streckenabschnitt zurückgelegt haben. Da das betrachtete Segment relativ gerade ist, können Vorzeichenänderungen des Lenkwinkels weniger auf die Streckengeometrie als auf den Fahrstil zurückgeführt werden. Eine Übereinstimmung der Messungen zu einer bestimmten Zeiteinheit ist folglich nicht zu erwarten; lediglich die Frequenz sowie die absolute Anzahl von Nulldurchgängen des Lenkwinkels N_L lassen sich sinnvoll vergleichen (Bild 5):

Wie angenommen, verursacht eine starke Gewichtung des Integralanteils ($k_{I1} > k_{I2}$) tatsächlich mehr Vorzeichenänderungen des Lenkwinkels ($N_{L1} > N_{L2}$).

Außerdem ist zu beobachten, dass beide Modellfahrer weniger korrigieren als menschliche Fahrer in einem vergleichbaren, realen Verkehrsumfeld. Dies lässt sich aber nicht abschließend beurteilen, da die Stichprobe sehr klein ist und deshalb Zufallsschwankungen nicht auszuschließen sind. Entscheidend ist aber, dass die Modellanpassungen theoriegeleitet vorgenommen wurden und die Lenkprofile einen vergleichbar hohen Wertebereich aufweisen. Deckungsgleiche Messergebnisse, die durch „Drehen“ an Parametereinstellungen erzielt werden, sind nicht gewollt.

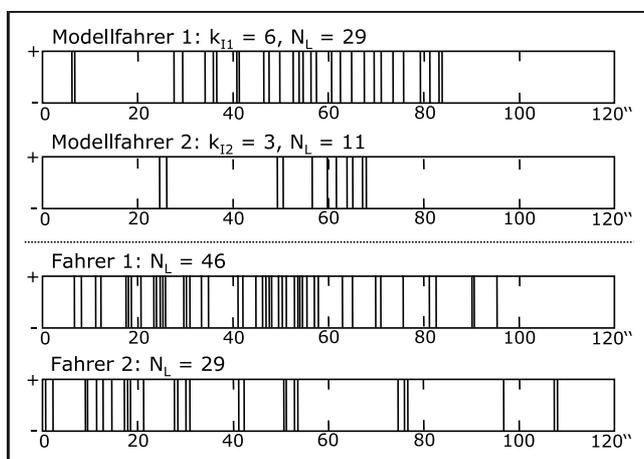


Bild 5: Vorzeichenwechsel des Lenkwinkels (Ordinate) über zwei Minuten Fahrt (Abszisse) für zwei Modellfahrer (oben) und zwei reale Fahrer (unten).

3.2 Strategische Ebene der Fahrzeugführung

Das oben beschriebene Lenkverhalten gilt als hoch automatisiert und fertigkeitstbasiert. Folglich wird diese operative Fahraufgabe auch nicht innerhalb der kognitiven Architektur abgebildet, sondern maßgeblich durch ein „vorgelagertes“ Lenkmodell beschrieben. Um nun in einem zweiten Schritt das Potenzial von ACT-R zu evaluieren, soll eine kognitive Aufgabe betrachtet werden: Hierfür eignen sich zum einen taktische Fahraufgaben, die regelbasiert erfolgen und zum Ziel haben, das Fahrzeug an den Straßenverlauf und den umgebenden Verkehr anzupassen (z. B. Überholmanöver [8]). Zum anderen können aber auch strategische Fahraufgaben betrachtet werden. Ein solches wissensbasiertes, bewusst gesteuertes Verhalten soll hier anhand einer Navigationsaufgabe untersucht werden; der Versuchsablauf (Abschnitt 3.2.1), die zugrunde liegende Hypothese (Abschnitt 3.2.2) sowie die Ergebnisse (Abschnitt 3.2.3) werden im Folgenden dargestellt.

3.2.1 Versuchsablauf

Die Untersuchung folgt dem Doppelaufgaben-Paradigma, wobei gleichzeitig eine Fahr- und eine Navigationsaufgabe zu bewältigen waren (ausführlichere Beschreibung siehe [11]): Bei der *Fahraufgabe* handelte es sich um eine simulierte Autobahnfahrt, die mit konstanter Geschwindigkeit und ohne Fremdverkehr zurückgelegt wurde.

Zusätzlich sollte zu bestimmten Zeitpunkten noch eine *Navigationsaufgabe* ausgeführt werden, die mit der Ansage eines fiktiven Ortsnamens angekündigt wurde. Nach etwa vier Sekunden wurde dann am rechten Bildschirmrand ein Autobahnwegweiser dargestellt. Dabei handelte es sich um Vorwegweiser für Anschlussstellen, die aus drei Geradeaus- und vier Abfahrtszielen bestanden (Bild 6). Die Aufgabe bestand darin, den Zielreiz zu suchen und dann so schnell und sicher wie möglich durch einen Tastendruck anzugeben, ob sich das Ziel unter den Abfahrts- oder den Geradeauszielen befand. Die Aufgabe wurde sowohl vom Fahrermodell als auch von 19 Probanden ausgeführt.

3.2.2 Hypothese

In dem Versuch wurde ein Multitasking-Szenario realisiert, das für menschliche Autofahrer alltäglich ist. Damit diese Aufgabe auch vom Fahrermodell zu bewältigen ist, waren zwei Ergänzungen erforderlich: Zum einen musste die visuelle Suchaufgabe modelliert werden. Hierzu wurde ein bereits bestehendes Modell, das die Menüsuche in grafischen Benutzeroberflächen [2] beschreibt, auf die Suche in Hinweisschildern [11] angepasst. Zum anderen wurde eine Erweiterung von ACT-R benutzt, Threaded-Cognition [12]. Dabei handelt es sich um eine Theorie, die beschreibt, wie Menschen zwei oder mehrere Aufgabenziele gleichzeitig ausführen.

Unabhängig davon, ob die Aufgabe nun von menschlichen Probanden oder vom Fahrermodell ausgeführt wird, erscheint folgende Annahme sinnvoll: *Die Doppelaufgabe stellt eine kognitive Beanspruchung dar, die dazu führt,*

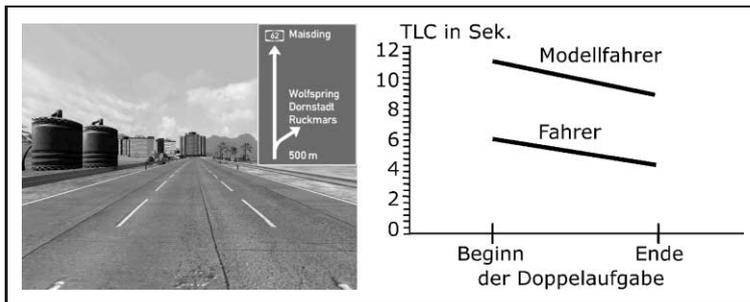


Bild 6: Links. Die Fahrsimulation basiert auf dem Microsoft XNA Racing Game, einem PC, einem kraftrückmeldenden Lenkrad und einem 19" Monitor; der vertikale Sichtwinkel für eine Schilderzeile betrug etwa 0,8–1,0°. Rechts. Spurhaltegröße zu Beginn und Ende der Doppelaufgabe.

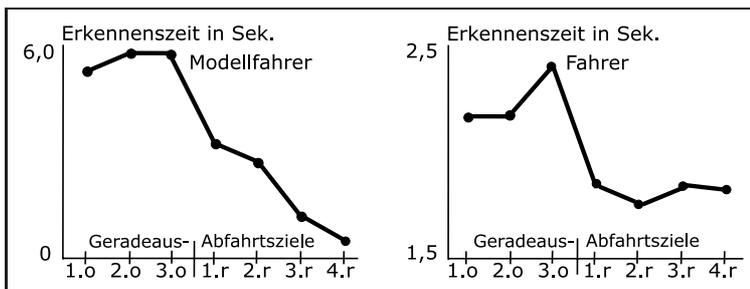


Bild 7: Erkennenszeiten für Ziele auf Hinweisschildern.

dass sich die Fahrleistung verschlechtert. Ein sensibler Indikator hierfür ist die Time-to-Line-Crossing (TLC). Dabei handelt es sich um die Zeit, in der das Fahrzeug, ausgehend vom aktuellen Querabstand und der Quergeschwindigkeit, eine Fahrspurbegrenzungslinie erreichen würde:

$$TLC_{\text{Beginn}} > TLC_{\text{Ende Doppelaufgabe}} \quad (7)$$

Außerdem sollten das Fahrermodell und die Probanden ungefähr gleich gut fahren, die Doppelaufgabe als ähnlich beanspruchend erleben sowie vergleichbar hohe Erkennenszeiten für die Ziele aufweisen.

3.2.3 Ergebnisse

Zur Auswertung wurde zunächst eine Varianzanalyse durchgeführt, wobei die Bedingungen Beginn/Ende der Doppelaufgabe beziehungsweise Modellfahrer/Fahrer die unabhängigen Variablen (UV) darstellen und die TLC als abhängige Variable betrachtet wird (Bild 6). Für beide UV zeigt sich ein signifikanter Haupteffekt; ein Interaktionseffekt konnte nicht nachgewiesen werden: Wie angenommen (7) verschlechtert sich daher sowohl die Fahrleistung des Modellfahrers als auch die der menschlichen Fahrer, wenn sie die Doppelaufgabe bearbeiten ($F_{(1,114)} = 49,336$, $p = 0,001$). Obwohl das Fahrermodell zwar insgesamt eine bessere Spurhaltung erzielen konnte als die Probanden ($F_{(1,114)} = 598,726$, $p = 0,001$), resultierte durch die Doppelaufgabe dennoch eine vergleichbar hohe kognitive Beanspruchung ($F = 0,012$, $p = 0,913$). Folglich ist das kognitive Modell zwar nicht deckungsgleich mit empirischen Ergebnissen, aber es kann die wesentlichen Aufgabencharakteristika durchaus abbilden.

Vergleicht man nun in einem zweiten Schritt den Modellfahrer und die menschlichen Fahrer hinsichtlich ihrer Suchzeiten in der Navigationsaufgabe, so sind zwei Punkte erwähnenswert (Bild 7): Das Modell weist eine größere

Spannweite auf; es braucht für Geradeausziele wesentlich länger als ein Mensch, während es Abfahrtsziele zum Teil schneller findet. Außerdem fällt auf, dass sowohl das Modell als auch die Probanden Abfahrtsziele insgesamt schneller finden als Geradeausziele. Fasst man die einzelnen Ziele zu zwei Gruppen zusammen, so ist der Unterschied sowohl für das Modell ($T = 9,172$; $p = 0,001$) als auch für die Probanden ($T = 2,158$; $p = 0,034$) signifikant. Folglich wählt das Fahrermodell eine ähnliche Suchstrategie wie menschlicher Fahrer. Zusammenfassend ist damit festzuhalten, dass das Fahrermodell im Bezug auf die strategische Fahraufgabe durchaus als valide zu bezeichnen ist.

4 Diskussion und Ausblick

Im Rahmen der Arbeit wurden vier verschiedene Ansätze zur Fahrermodellierung vorgestellt, wobei insbesondere die Modellierung mit ACT-R [7] vertieft wurde: In dem Zusammenhang wurde gezeigt, dass das von Salvucci [8] vorgeschlagene Fahrermodell in der Lage ist, individuelle Unterschiede im Lenkverhalten abzubilden. Darüber hinaus wurde auch demonstriert, dass das Modell strategische Fahraufgaben ähnlich wie ein Mensch bearbeiten kann. In derzeit laufenden Forschungsarbeiten wird das bestehende Fahrermodell zum einen weiterentwickelt (z. B. zusätzliche Bewegungsinformation durch optischen Fluss) und zum anderen zur Entwicklung kognitiver Automobile genutzt.

Der gegenwärtige Fokus liegt dabei auf dem Fahrzeug MuCar-3 (*Munich Cognitive Autonomous Robot Car 3rd Generation*). Zum Testen von Verhaltensalgorithmen verfügt das Automobil über die Simulationsumgebung *SiMuCar* (Bild 8). Mit dieser lassen sich unterschiedliche Verkehrsszenarien (z. B. Autobahn mit Ein-/Ausfahrten) sowie statische und dynamische Aspekte der Verkehrsumwelt (z. B. Fremdverkehr) generieren. Außerdem ist es möglich, Realweltdaten einzubinden und so tatsächlich existierende

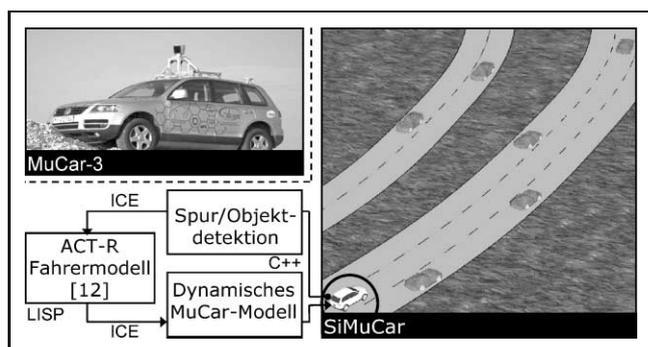


Bild 8: Das autonome Fahrzeug MuCar-3 und dessen Simulationsumgebung SiMuCar.

Umweltbedingungen zugrunde zu legen (z. B. GPS-Daten einer abgefahrenen Strecke). Als Wahrnehmungsgrundlage stehen Fahrbahnmarkierungen oder weitere Objekte der Verkehrsumwelt zur Verfügung, wie sie auch durch die Auswertung von Kamera- oder Lidardaten vorliegen würden. Die Simulationsumgebung wurde erweitert, indem neben dem MuCar-Modell auch das oben beschriebene Fahrermodell implementiert wurde. Der Datenaustausch zwischen dem Modell und SiMuCar wurde dabei über *ICE* (Internet Communications Engine) realisiert.

Bedenkt man, dass über 90% der Verkehrsunfälle auf menschliche Fehler zurückzuführen sind, steht eine mächtige Versuchsumgebung zur Verfügung: Durch das Fahrermodell ist es möglich, „realistischen“ Fremdverkehr für MuCar zu simulieren. Wie auch menschliche Fahrer, wird sich das Fahrermodell mitunter fehlerhaft verhalten (z. B. Aufmerksamkeits-, Gedächtnis-, und Regelfehler) sowie Verletzungen der Straßenverkehrsordnung begehen. Dies stellt eine optimale Möglichkeit dar, um unter sicheren und wiederholbaren Bedingungen zu testen, inwieweit das autonome Fahrzeug zu kooperativem Verkehrsverhalten fähig ist.

Danksagung

Diese Arbeit wurde durch die DFG (SFB Kognitive Automobile, Exzellenzcluster CoTeSys) unterstützt.

Literatur

- [1] C. Stiller: Intelligente Fahrzeuge. In: *Autonome Mobile Systeme 2007*, 20. Fachgespräch Kaiserslautern (S. 163–170). Springer, Berlin 2008.
- [2] M. Byrne: ACT-R/PM and menu selection. In: *Int. Journal of Human-Computer Studies* 55 (2001) Nr. 1, S. 41–84.

- [3] J. Michon: A critical view of driver behavior models. What do we know, what should we know? In: L. Evans und R. Schwing (Hrsg.), *Human behavior and traffic safety* (S. 485–525), Plenum Press, New York, 1985.
- [4] A. Benmimoun: The Driver as Archetype for Driver Assistance Systems? A Driver-Model Based Approach for the Development of Situation-Adaptive DAS. 13. Aachener Kolloquium Fahrzeug und Motorentechnik, 4–6. Okt. 2004.
- [5] T. Bellet, B. Bailly et al.: Cognitive Modelling and Computational Simulation of Drivers Mental Activities. In: P. Cacciabue (Hrsg.), *Modelling Driver Behaviour in Automotive Environments* (S. 315–343). Springer, Berlin 2007.
- [6] C. Wu und Y. Liu: Queuing Network Modeling of Driver Workload and Performance. In: *IEEE Transactions on Intelligent Transportation Systems* 8 (2007) Nr. 3, S. 528–537.
- [7] J. Anderson, D. Bothell, et al.: An Integrated Theory of the Mind. In: *Psychological Review* 111 (2004) Nr. 4, S. 1036–1060.
- [8] D. Salvucci: Modeling driver behavior in a cognitive architecture. In: *Human Factors* 48 (2006) Nr. 2, S. 362–380.
- [9] D. Salvucci und R. Gray: A two-point visual control model of steering. In: *Perception* 3 (2004) Nr. 10, S. 1233–1248.
- [10] E. Hildreth, J. Beusmans, et al.: From vision to action: Experiments and models of steering control during driving. In: *Journal of Experimental Psychology* 26 (2000) Nr. 3, S. 1106–1132.
- [11] M. Halbrügge, B. Deml, et al.: ACT-CV: Kognitive Benutzermodelle interagieren mit der Außenwelt. In: M. Grandt (Hrsg.), *Stand und Perspektiven der simulationsgestützten Systemgestaltung* (S. 313–331). DGLR, Bonn 2007.
- [12] D. Salvucci und N. Taatgen: Threaded cognition: An integrated theory of concurrent multitasking. In: *Psychological Review* 115 (2008) Nr. 1, S. 101–130.

Manuskripteingang: 9. Juni 2008.

Prof. Dr.-Ing. Barbara Deml ist Juniorprofessorin für Kognitive Ergonomie am Institut für Arbeitswissenschaft. Hauptarbeitsgebiete: Kognitive Modellierung, Mensch-System-Schnittstellen.

Adresse: Universität der Bundeswehr, Werner-Heisenberg-Weg 39, 85577 Neubiberg, E-Mail: barbara.deml@unibw-muenchen.de

Dipl.-Psych. Hendrik Neumann ist wissenschaftlicher Mitarbeiter am Institut für Arbeitswissenschaft, UniBW. Hauptarbeitsgebiete: Kognitive Modellierung.

Adresse: wie oben, E-Mail: hendrik.neumann@unibw-muenchen.de

Dipl.-Ing. André Müller ist wissenschaftlicher Mitarbeiter an der Professur Technik Autonome Systeme, UniBW. Hauptarbeitsgebiete: Kognitive Automobile.

Adresse: wie oben, E-Mail: andre.mueller@unibw.de

Prof. Dr.-Ing. Hans Joachim Wünsche ist Inhaber der Professur Technik Autonome Systeme, UniBW. Hauptarbeitsgebiete: Kognitive Automobile.

Adresse: wie oben, E-Mail: joe.wuensche@unibw-muenchen.de