



Fakultät II – Informatik, Wirtschafts- und Rechtswissenschaften
Department für Informatik

Das Adaptive-Information- Expectancy-Modell zur Aufmerksamkeitssimulation eines kognitiven Fahrermodells

Dissertation zur Erlangung des Grades eines
Doktors der Naturwissenschaften

vorgelegt von

Dipl.-Inform. Bertram Wortelen

Gutachter:

Prof. Dr. Claus Möbus

Prof. Dr. Martin Fränzle

Tag der Disputation:

19. Juni 2014

Zusammenfassung

Bei Unfällen auf deutschen Straßen kommt es jährlich zu mehreren hunderttausend Verletzten und mehreren tausend Todesopfern. Mit immer neuen Automations-systemen, die den Fahrer unterstützen und Teile der Fahraufgabe automatisieren, versucht die Automobilbranche diesen Opferzahlen entgegen zu wirken. In der Luft-fahrt-domäne hat sich gezeigt, dass die Einführung von Automationssystemen trotz des grundsätzlich positiven Effekts auch negative Nebeneffekte mit sich bringt. Oft wird der automatisierten Aufgabe zu wenig Aufmerksamkeit geschenkt, um in Ge-fahrensituationen schnell reagieren zu können (Out-of-the-loop-Effekt).

Um bei der Entwicklung neuer Automationssysteme frühzeitig unerwünschte Ne-beneffekte zu identifizieren, werden Modelle zur Vorhersage der Aufmerksamkeits-vertei-lung benötigt. Heutige Modelle ermöglichen jedoch nur Vorhersagen auf ei-nem sehr niedrigen Detaillevel. Das populäre und einfach anwendbare SEEV-Modell liefert lediglich Vorhersagen zur prozentualen Aufteilung der Aufmerksamkeit auf verschiedene Informationsquellen. Dabei wird jedoch die komplexe Interaktion zwi-schen der Aufmerksamkeitsverteilung des Fahrers und den Aufgaben, die der Fahrer durchführt (z.B. die Fahrzeugführung, Beobachtung des Verkehrs und die Interak-tion mit Fahrzeugsystemen), nicht berücksichtigt.

In dieser Arbeit wird mit dem Adaptive-Information-Expectancy (AIE)-Modell ein neues Modell der Aufmerksamkeitsverteilung präsentiert, das in kognitive Archi-tekturen integriert werden kann, die zur Simulation von Aufgabenmodellen dienen. Es ist eine Erweiterung des SEEV-Modells und ermöglicht eine detailliertere Si-mulation der Aufmerksamkeitsverteilung in enger Interaktion mit der Simulation des Aufgabenmodells, als dies mit dem aktuellen Stand der Forschung realisierbar ist. Anders als beim SEEV-Modell lassen sich bei der Simulation des AIE-Modells neben der prozentualen Blickverteilung weitere Kenngrößen der visuellen Aufmerk-samkeitsverteilung ermitteln, wie Blickfrequenzen und Blicktransitions-wahrscheinlichkeiten. Durch die enge Integration mit der Simulation des Aufgabenmodells las-sen sich zudem die daraus resultierenden Auswirkungen auf das Verhalten bei der Aufgabenbearbeitung simulieren. Es werden im AIE-Modell zwei Faktoren berück-sichtigt, die einen großen Einfluss auf die Aufmerksamkeit von Autofahrern haben: die Erwartung von Ereignissen und der Wert von Informationen. Der Hauptfokus liegt auf der Ereigniserwartung. Hierzu wird ein neues Verfahren vorgestellt, das die Ereigniserwartung automatisch aus der Simulation eines Aufgabenmodells er-mittelt, so dass eine manuelle Bestimmung der Ereigniserwartung entfällt.

In einem ersten Schritt wird demonstriert, wie sich das AIE-Modell in die kogniti-ve Architektur CASCaS integrieren lässt. Mithilfe dieser Architektur werden zwei Evaluationsszenarien untersucht. Im ersten Szenario wird eine Laboraufgabe ver-wendet, die fokussiert den Einfluss der Ereigniserwartung betrachtet. Vergleiche der Simulationsergebnisse des AIE-Modells mit Daten aus der Literatur zum Verhalten von Versuchspersonen zeigen eine sehr gute Übereinstimmung.

Für das zweite Szenario wird eine Fahrsimulatorstudie durchgeführt, um das AIE-Modell in einer realistischen Fahrsimulation zu analysieren. Das Simulationsszena-rio wird sowohl von menschlichen Versuchsfahrern durchfahren als auch von einem Fahrermodell unter Verwendung des AIE-Modells. In diesem Szenario wird sowohl der Einfluss der Ereigniserwartung als auch der Einfluss des Informationswertes auf die Aufmerksamkeitsverteilung untersucht. Bei der Fahrsimulation zeigen sich die Vorzüge des AIE-Modells besonders gut. Das Blickverhalten der Versuchsfahrer wird sehr gut durch das AIE-Modell wiedergegeben. Zudem lassen sich auch die daraus resultierenden Effekte auf die Fahrzeugführung dank der engen Integration mit dem Aufgabenmodell simulieren.

Abstract

Every year, several hundreds of thousands of people are injured and several thousands are killed in accidents on German roads. The automotive industry tries to counteract these numbers by introducing more and more automation systems into vehicles which support the driving task and partially automate it. A similar process in the aviation domain revealed that the introduction of new automation systems induces, besides the generally positive effects, also negative side effects. Often, too little attention is paid to the automated tasks with the result that reactions in dangerous situations are too slow (out-of-the-loop effect).

Predictive models of attention distribution are required to identify undesired side effects early in the design process of new automation systems. However, today's state-of-the-art models offer predictions on a low level of detail. The popular and easy to use SEEV model only provides predictions of the percentage distribution of attention to a set of information sources. More detailed predictions are not possible with the SEEV model alone. It especially does not consider the complex interactions between the distribution of driver's attention and the tasks that the driver is executing (e.g. vehicle control, monitoring of surrounding traffic, interaction with in-vehicle systems).

This thesis presents the Adaptive Information Expectancy (AIE) model, a new model of attention distribution, which is based on the SEEV-model. It can be integrated into cognitive architectures which are used to simulate task models. The AIE model enables a more detailed simulation of the distribution of attention in close interaction with the simulation of a task model than what is possible with current state-of-the-art models. Unlike the SEEV model, simulations using the AIE model allow to derive several measures of human attention distribution besides the percentage gaze distribution, like gaze frequencies and gaze transition probabilities. Due to the tight integration with the simulation of task models, it is also possible to simulate the resulting consequences on the operator's behaviour (e.g. steering behaviour of drivers). The AIE model considers two factors which have a great impact on drivers' attention: the expectancy of events and the value of information. The main focus is on the expectancy of events. The AIE model provides a new method to automatically determine the event expectancy from the simulation of a task model. The need to determine this factor manually is therefore eliminated.

After the description of the AIE model, it is shown how it is integrated in the cognitive architecture CASCaS. Using CASCaS, the AIE model is analysed in two evaluation scenarios. The first one uses a laboratory task which focuses on investigating the influence of the event expectancy. Comparisons between the simulation data of the AIE model and data from literature on human behaviour for this task show a very good correlation.

For the second scenario, a driving simulator study is performed to analyse the AIE model in a realistic driving environment. The simulation scenario is driven by human drivers as well as by a driver model using the AIE model. This scenario investigates the effects of both factors on drivers' attention distribution: event expectancy and information value. The driving simulation reveals the advantages of the AIE model. The gaze behaviour is very well replicated by the AIE model. Furthermore, the AIE model also demonstrates its ability to simulate the resulting effects on the driving behaviour due to its tight integration with the simulation of the task model.

Danksagung

Während der Arbeiten an dieser Dissertation habe ich mich mit einigen interessanten Problemstellungen beschäftigt. Dabei erhielt ich auf verschiedenste Weise Unterstützung von zahlreichen Personen, bei denen ich mich an dieser Stelle herzlich bedanken möchte.

Die langjährige Arbeit an einer Dissertation ist oftmals von produktiven und ergiebigen Zeiten, als auch von schwierigen Zeiten geprägt. So auch in meinem Fall. Ein besonderer Dank geht daher an die Menschen, die mir in schwierigen Zeiten weiter geholfen haben. So haben mir die Diskussionen mit meinem Gruppenleiter beim OFFIS, Andreas Lüdtke, der die Arbeit von Beginn an begleitet hat, sehr geholfen. Ich weiß die Freiräume, die ich während der Arbeit erhalten habe und den Ansporn zu immer neuen Schritten sehr zu schätzen. Sehr dankbar bin ich auch Sebastian und Katrin, die mich ebenso immer wieder angespornt haben.

Des Weiteren möchte ich mich bei meinen Kollegen vom OFFIS und der Uni Oldenburg, als auch bei Martin Baumann vom DLR Braunschweig für die sehr angenehme Zusammenarbeit und Unterstützung bedanken.

Bertram Wortelen
Oldenburg, im September 2014

Für meine Eltern.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Motivation	1
1.2	Zielsetzung	6
1.3	Publikationen	8
1.4	Aufbau der Arbeit	8
2	Grundlagen und Stand der Forschung	11
2.1	Blickverhalten und Aufmerksamkeit	11
2.2	Kognitive Architekturen	29
2.3	Die kognitive Architektur CASCaS	40
2.4	Fahrermodelle	57
2.5	Beitrag zum Stand der Forschung	59
3	Konzeptionierung des AIE-Modells	61
3.1	Aufgabenstruktur	63
3.2	Zielauswahl	68
3.3	Operationalisierung der Modellparameter	71
3.4	Lernphase	77
3.5	Initialisierung	80
3.6	Diskussion	80
3.7	Integration in CASCaS	85
3.8	Zusammenfassung	88
4	Evaluation I: Senders' Monitoring-Aufgabe	91
4.1	Senders' Experimentreihe	92
4.2	Agentenmodell	94
4.3	Simulationsergebnisse	96
4.4	Zusammenfassung	111
5	Evaluation II: Fahr Simulatorstudie	113
5.1	Hypothesen	115
5.2	Versuchsaufbau	117
5.3	Vorhersagen des SEEV-Modells	123
5.4	Datenaufbereitung	125
5.5	Ergebnisse	127
5.6	Fahrermodell	138
5.7	Parameterschätzung der Lateral- und Longitudinalkontrolle	148
5.8	Simulationsergebnisse	150
5.9	Zusammenfassung	175

6 Zusammenfassung und Diskussion	179
6.1 Zusammenfassung	179
6.2 Diskussion	182
6.3 Fazit	187
A Formale Semantik des AIE-Modells	189
B Details zur Fahrstudie	193
B.1 Versuchspersonen	193
B.2 Versuchsbedingungen	194
B.3 Formulare	194
B.4 Experimentprotokoll	199
B.5 Ergebnisse der Anova	202
C Datenbanken	209
C.1 Senders Monitoring-Aufgabe	210
C.2 Fahrstudie	214
D Prozedursyntax	221
E Identifikation der freien Parameter	229
Glossar	231
Abkürzungsverzeichnis	241
Literatur	243
Index	265

Kapitel 1

Einleitung

1.1 Motivation

Viele Bereiche der Industrie und des täglichen Lebens haben in den letzten Jahrzehnten einen Anstieg an Automatisierung erfahren. Insbesondere der Bereich der industriellen Prozessautomation hat einen starken Umsatzanstieg verzeichnet (VDMA, 2012). Die Automatisierung unterstützt den Menschen bei seiner Arbeit. Viele komplexe industrielle Prozesse lassen sich überhaupt erst durch computergestützte Automatisierung handhaben. Der Mensch nimmt hierbei zunehmend die Aufgabe eines Überwachers ein, der das Automationssystem beobachtet und bei Bedarf lenkend eingreift (Berberian et al., 2012).

Oftmals geht mit solchen Aufgaben ein hohes Maß an Verantwortung einher. Dies ist insbesondere bei sicherheitskritischen oder kostenintensiven Systemen der Fall. So können Fehler beim Führen von Fahrzeugen, sei es im Straßen-, Bahn-, oder auch Flugverkehr, zu einem Verlust von Menschenleben oder einer Beschädigung des Transportsystems führen. Aber auch bei der Kontrolle von vielen industriellen Anlagen wie Kraftwerken oder Chemieanlagen kann ein Bedienfehler katastrophale Auswirkungen haben.

Leider kommt es jedoch immer wieder zu Unfällen, die durch menschliches Fehlverhalten entstehen (Parasuraman und Riley, 1997; Shappell und Wiegmann, 2004). Ursache im Zusammenhang mit komplexen Mensch-Maschine-Systemen kann sowohl die Maschine als auch der menschliche Operator sein. Häufig finden sich ursächliche Faktoren auf beiden Seiten in einer Abfolge ungünstiger Ereignisse, die schließlich zu einem Unfall führen (Leveson, 2011). Solange kein technisches Fehlverhalten auftritt, trägt jedoch in der Regel der menschliche Bediener die Verantwortung für das Geschehen.

Die Tiefenanalyse eines Unfalls deckt oft auf, dass viele weitere Faktoren wie die Trainingsprozeduren oder das Systemdesign einen entscheidenden Einfluss auf die Wahrscheinlichkeit von Bedienfehlern haben (Leveson, 2011, S. 37). Ein übersichtliches und für den Bediener leicht verständliches System wird in den meisten Fällen zu deutlich weniger Fehlern führen. Der Systementwickler sollte daher nicht nur dafür Sorge tragen, dass das System vorschriftsmäßig funktioniert, sondern auch nach Möglichkeit das System so gestalten, dass der spätere Benutzer bei der Bedienung optimal unterstützt wird.

Mit steigender Komplexität der Maschine steigt in der Regel auch die Anforderung an den menschlichen Operator der Maschine. Seit Mitte des 20. Jahrhunderts rückte nun die Interaktion zwischen Mensch und Maschine zunehmend in den Fo-

kus von Untersuchungen. Ziel ist es, die Leistung des Mensch-Maschine-Systems zu optimieren, Unfälle zu reduzieren und eine optimale Ausnutzung der menschlichen Arbeitskraft zu erlangen. Beispiele finden sich unter anderem im Luft- und Raumfahrtbereich (Fitts et al., 1950), sowie bei der Unterhaltung industrieller Großanlagen (Senders, 1983).

1.1.1 Mensch und Automation

Die Automation von ehemals manuellen Prozessschritten bietet viele Vorteile. Sie reduziert die Arbeitsbelastung des menschlichen Bedieners und erhöht häufig die Präzision und Wirtschaftlichkeit der Systeme. So reduzierte die Einführung des Autopiloten im Luftfahrtbereich die Arbeitsbelastung des Piloten erheblich, da dieser vorher Kurs und Höhe des Flugzeugs kontinuierlich kontrollieren musste (Agarwal und Subramaniam, 2008). Durch den Einsatz solcher Systeme lassen sich Langstreckenflüge selbst mit einer kleinen Crew sicher durchführen. Jedoch bedeutet eine optimale Unterstützung des Benutzers durch das System nicht immer, dass möglichst viele Aufgaben automatisiert werden. Durch Automationsprozesse können auch neue Probleme entstehen, insbesondere in Fällen, in denen ein Kommunikationsaustausch zwischen Mensch und Maschine nötig ist (Dekker, 2005). So traten im Luftfahrtbereich Fälle auf, in denen sich Piloten unangemessen verhielten, da ihnen der Zustand des Automationssystems nicht vollständig bekannt war und das Verhalten der Maschine nicht den eigenen Erwartungen entsprach (Sarter et al., 1997).

Durch die Automation verändert sich auch die grundsätzliche Rolle des Benutzers. Anstelle das System manuell zu kontrollieren, überwacht der menschliche Bediener lediglich das Automationssystem (Leveson, 2011; Berberian et al., 2012). Der Mensch ist oftmals nicht gut dafür geeignet, eine überwachende Tätigkeit auszuführen (Endsley und Kaber, 1999). Es wird insbesondere dann kritisch, wenn diese Tätigkeit kaum Eingriffe erfordert. In einer solchen Situation kann überwachende Tätigkeit schnell ermüdend werden und die Aufmerksamkeit des Menschen auf die jeweilige Aufgabe reduzieren (Leveson, 2011). Solche unbewussten Auswirkungen von Automations- und Assistenzsystemen sind ebenfalls eine mögliche neue Gefahrenquelle, die erst durch die Einführung von Automationssystemen entsteht.

Die schwierige Frage, die es daher bei Automationsprozessen zu lösen gilt, ist nicht unbeding, welche Funktion sich weiter automatisieren lässt, sondern wie eine gute Kooperation zwischen Mensch und Maschine erreicht werden kann (Dekker, 2005). Dabei ist der Automationsgrad sorgfältig zu wählen, so dass der Mensch zwar entlastet wird, aber dennoch durch fehlendes Situationsbewusstsein oder fehlende Eingriffsmöglichkeiten keine neuen Gefahrenquellen entstehen. Häufig ist es möglich, den Grad der Automation sehr feingranular zu wählen. Endsley und Kaber (1999) geben beispielsweise eine Klassifizierung von Automationsgraden in zehn Leveln an. Eine ähnliche Taxonomie ebenfalls mit zehn Leveln wurde auch von Sheridan und Verplank (1978) definiert.

Auch in den nächsten Jahren ist damit zu rechnen, dass die Automation sowohl im privaten als auch im beruflichen Leben weiter zunehmen wird, denn insbesondere die stark zunehmende Vernetzung von Alltags- und Berufsgegenständen besitzt ein enormes Potential für neue Anwendungen und Automatisierungsmöglichkeiten. In der industriellen Produktion wird unter dem Stichwort *Industrie 4.0* in der gesamtheitlichen Vernetzung von Produkt, Produktionsprozessen bis hin zu den Verbrauchern sogar die nächste industrielle Revolution gesehen (Schleidt, 2012). Ein ähnlicher Umbruch zeichnet sich auch im Straßenverkehr ab. Hier soll die Ver-

netzung von Fahrzeugen mit der Verkehrsinfrastruktur und Leitständen sowie die Vernetzung von Fahrzeugen untereinander, dem Fahrzeug die Informationen zur Verfügung stellen, die für weitere Automations Schritte bis hin zur Vollautomation nötig sind (IHS Global Insight, 2012).

Um die oben genannten Probleme bei der Einführung neuer Automationsysteme zu vermeiden, sollte der Faktor Mensch bei der Systementwicklung explizit berücksichtigt werden. Eine ausführliche Evaluation eines neuen Systems durch den Nutzer geschieht jedoch meistens erst nach Inbetriebnahme des Systems in Feldstudien. Bei sicherheitsunkritischen Anwendungen, wie sie beispielsweise in der Unterhaltungsindustrie vorkommen, ist dieses Vorgehen durchaus akzeptabel. Für sicherheitskritische oder kostenintensive Systeme ist es jedoch essentiell, dass möglichst viele potentielle Fehlerquellen bereits vor Markteinführung beseitigt werden, um Schaden an Mensch und Material zu vermeiden.

Sehr häufig spielt bei der Überwachung sicherheitskritischer Systeme die visuelle Aufmerksamkeit des Benutzers eine sehr wichtige Rolle für die Sicherheit, da die Reaktionszeit in einer kritischen Situation u. a. davon abhängt, wie schnell der Benutzer diese als solche erkennt. Bei der Analyse eines neuen Systems sollte daher ein besonderes Augenmerk darauf gelegt werden, wie das System die Aufmerksamkeit des Benutzers beeinflusst.

1.1.2 Automation und Aufmerksamkeit im Fahrzeug

Seit der Zeit der ersten Automobile gibt es einen konstanten Prozess technischer Neuerungen und Weiterentwicklungen. Heutzutage findet sich eine Vielzahl an Systemen im Fahrzeug, die unterschiedliche Aspekte der Fahraufgabe auf sehr unterschiedlichen Automationsgraden automatisieren (Frey mann, 2004). Für die Aufgabe der Längsführungskontrolle existieren informierende Systeme wie z.B. Abstandswarner, genauso wie aktiv eingreifende Systeme. Dazu zählen z.B. Systeme, die aktiv kurz vor Kollisionen eingreifen (engl.: Precrash Systems), indem sie die Sicherheitsgurte straffen, den Bremsdruck erhöhen oder sogar aktiv Notbremsungen einleiten. Auch teilautonome existieren, die über einen längeren Zeitraum aktiv die Längsführungsregelung übernehmen. Dies sind zum Beispiel Cruise Control Systeme, die die Aufgabe der Geschwindigkeitsregelung übernehmen, sowie Adaptive Cruise Control (ACC) Systeme, die zusätzlich auch die Abstandsregelung durchführen.

Auch für andere Aspekte der Fahraufgabe, wie Querführung und Navigation, finden sich ähnliche Assistenzsysteme mit unterschiedlichen Automationsgraden. Zudem bergen aktuelle Entwicklungen z. B. in der Car-to-Car (C2C)- und Car-to-Infrastructure (C2I)- Kommunikation sowie im Bereich intelligenter Sensornetze ein großes Potential für weitere Automations Schritte. Der Weg zur Vollautomation ist bereits absehbar. Eine mögliche Roadmap mit nötigen Zwischenschritten wird zum Beispiel von Winner und Wolf (2009) gegeben.

Die DARPA¹ Urban Challenge zielt dagegen direkt auf das ambitionierte Ziel der Vollautomation ab, indem es internationale Teams ermutigt, Fahrzeuge zu entwickeln, die eigenständig in städtischen Umgebungen mit realem Verkehr fahren können. Einige dieser Teams haben ihre Fahrzeuge bereits im realen Verkehr getestet, wie das deutsche Team der TU Braunschweig mit ihrem Fahrzeug Leonie (Rauskolb et al., 2008; Saust et al., 2011) und das Google Team um Sebastian Thrun, das bereits eine Flotte von sieben autonomen Fahrzeugen auf öffentlichen Straßen testete.

¹www.darpa.mil

Um weitere Tests zu erleichtern, können seit März 2012 im US Bundesstaat Nevada vollautonome Fahrzeuge sogar offiziell zugelassen werden ([Legislat ure, 2012](#)).

Neben der Automation ist ein weiterer Trend im Automobilbereich abzusehen: Die Anzahl und Qualität von **Infotainmentsystemen** wird in naher Zukunft auch im Automobilbereich weiter ansteigen ([Löwer und Bolduan, 2011](#)). Bereits jetzt existieren Infotainmentsysteme, wie das BMW ConnectedDrive-System ([BMW Group, 2012](#)) oder das AutoLinQ-System von Continental ([Continental AG, 2011](#)), die freien oder begrenzten Zugriff auf das Internet zulassen, auf Standardbetriebssystemen aufsetzen oder frei verfügbare Software Development Kits anbieten. Dabei wird von Beginn an auf existierende Technologien und Marktplätze aus dem Smartphone-Bereich zurückgegriffen, um eine einfache Einbindung von Drittanbieter-Applikationen in das Infotainmentsystem zu ermöglichen. Eine vergleichbare technologische Entwicklung hat bei Smartphones zu einem rapide wachsenden Markt von Apps geführt. Beim Autofahren können diese Apps die durch die Automation frei werdenden Ressourcen, wie die visuelle Aufmerksamkeit, leicht an sich binden.

Eine Abschätzung darüber, wie neue Assistenz-, Informations- oder Entertainmentssysteme das Blickverhalten von Autofahrern beeinflussen werden, kann eine sehr wertvolle Information für den Systemdesigner sein, insbesondere wenn mehrere Designalternativen zur Auswahl stehen. Vor allem die Anzahl und Dauer der Blicke, die nicht auf den Verkehr und die Straße vor dem Fahrzeug gerichtet sind, sind kritisch, denn sie beeinträchtigen die Reaktionszeit auf Bremsaktionen des vorausfahrenden Fahrzeugs erheblich ([Summala et al., 1998](#)). Zudem erlauben sich Fahrer im Verhältnis zu ihrem Sicherheitsabstand häufig zu lange Blicke weg vom vorausfahrenden Fahrzeug, da sie durch lange Fahrerfahrung gelernt haben, dass das vorausfahrende Fahrzeug normalerweise nicht abrupt bremsen wird ([Tijerina et al., 2004](#)).

Auch bei den Unfallzahlen bestätigt sich das Gefahrenpotenzial einer unangemessenen Blickverteilung. Nach einer amerikanischen Feldstudie ([Dingus et al., 2006](#)) haben Autofahrer bei 78% aller Unfälle eine Zeit lang nicht nach vorne geschaut. Bei Auffahrunfällen war dies in 93% der Unfälle der Fall. Ähnlich hohe Zahlen finden sich auch bei anderen Unfallanalysen. So gibt eine weitere Studie ([Knippling, 1993](#)) Unaufmerksamkeit als eine Ursache bei 90% der Auffahrunfälle an. Eine weitere beziffert den Effekt von Fehlern in der Informationswahrnehmung ursächlich für über 60% aller Unfälle ([Graab et al., 2008](#)). Diese Zahlen lassen sich zwar schwer direkt vergleichen, da jeweils leicht unterschiedliche Definitionen von Unaufmerksamkeit und unterschiedliche Fahrerpopulationen berücksichtigt wurden, jedoch zeigen sie eindrucksvoll, wie wichtig die visuelle Aufmerksamkeit für die sichere Fahrzeugführung ist. Neben der Verhinderung von Schäden an Leib und Leben spielen auch ökonomische Aspekte eine Rolle. So beliefen sich die volkswirtschaftlichen Kosten von Verkehrsunfällen 2009 alleine in Deutschland auf 30,52 Mrd. Euro ([Straube, 2011](#)).

Konstante Bemühungen in den letzten 40 Jahren haben die jährlichen Todesopfer im deutschen Straßenverkehr um etwa 75% Prozent verringert (s. [Abbildung 1.1](#)). Mit 3648 Todesopfern im Jahr 2010 ([Statistisches Bundesamt, 2014](#)) hat die Bundesrepublik damit das ehrgeizige Ziel der Europäischen Kommission, die jährlichen Verkehrstoten im Zeitraum von 2001 bis 2010 zu halbieren ([European Commision, 2001, S. 66](#)), sehr knapp nicht erreicht (Verkehrstote 2001: 6977). Für 2020 hat sich die Kommission das Ziel gesetzt die Todeszahlen erneut zu halbieren basierend auf den Zahlen von 2010 ([European Commision, 2010, S. 4](#)). Um diesen positiven Trend fortzuführen, erscheint es daher sinnvoll die Fahreraufmerksamkeit als eine wichtige Unfallursache näher zu betrachten.




Abbildung 1.1 – Tote und Verunglückte im Straßenverkehr der Bundesrepublik Deutschland (1960-2012) (Statistisches Bundesamt, 2014)

1.1.3 Integrierte System- und Benutzersimulation

Zur Untersuchung des zu erwartenden Benutzerverhaltens bei Einführung neuer Assistenzsysteme existieren verschiedene komplementäre Ansätze. Ein bewährter Weg ist es, das fertige System oder einen Prototypen durch Versuchspersonen testen zu lassen (Serval et al., 2006). Im Automobilbereich werden hier häufig **Human-in-the-Loop-Simulationen** in Fahr simulatoren durchgeführt. Ein großer Vorteil bei diesem Verfahren besteht darin, dass die Reaktionen der Versuchspersonen sehr einfach beobachtet werden können. Zudem können die Versuchspersonen ihre subjektiven Eindrücke und Meinungen zum System direkt äußern. Eine zusätzliche Datenaufzeichnung während der Versuche erlaubt zudem eine weitere objektive Messung des Systemeinflusses auf das Fahrerverhalten. Der Zeit- und Kostenaufwand ist bei diesem Ansatz jedoch relativ hoch, da die Versuchspersonen bezahlt und betreut werden müssen und sich die Durchführung der Studien nur schwer beschleunigen lässt. Zudem ist das Hardware-Equipment je nach gewünschtem Realitätsgrad sehr teuer.

Eine weitere Alternative besteht darin, Human-Factor-Experten zu Rate zu ziehen, die auf Basis des Systementwurfes Aussagen zu erwarteten Verhaltenseffekten machen. Dies ist insbesondere in frühen Designphasen eine gute Option, da die Experten bereits mit informellen Beschreibungen arbeiten können.

Die vollständig modellbasierte Closed-Loop-Simulation des Systems aus Fahrer², Fahrzeug und Umgebung ist eine weitere Alternative zur Systemevaluierung (z. B. Salvucci, 2009), die mit dieser Arbeit unterstützt werden soll. Hierbei wird die menschliche Versuchsperson durch ein ausführbares Simulationsmodell ersetzt. Der Vorteil gegenüber Human-in-the-Loop-Simulationen besteht vor allem darin, dass sich die Simulationen sehr gut skalieren lassen. So können zum einen viele Simulationen gleichzeitig durchgeführt werden und zum anderen können die Simulationen selbst beschleunigt werden, da eine Simulation in Echtzeit nicht notwendig ist. Auf

²Um den Lesefluss zu verbessern, wird in den folgenden Texten nur von "dem Fahrer" bzw. "dem Versuchsteilnehmer" gesprochen. Diese Formulierung soll weibliche Versuchspersonen und Fahrerinnen natürlich mit einschließen.

diese Weise können viele Szenarien untersucht und Zeit gespart werden. Zudem bieten die Menschmodelle eine gute Möglichkeit, das Wissen von Human-Factor-Experten zu formalisieren und zu bündeln.

Nachteil dieses Ansatzes ist jedoch, dass der Mensch als Einzelsystem sehr komplex ist und Menschmodelle stets eine starke Abstraktion darstellen. Güte und Detailgrad der Menschmodelle sind jedoch entscheidende Einflussfaktoren für die Aussagekraft dieses Ansatzes.

Im Optimalfall lassen sich nach der Integration des Assistenzsystems in das System aus Fahrer, Fahrzeug und Umgebung und der Erstellung einer formalen Beschreibung der Mensch-System-Interaktion Simulationen durchführen, die die gewünschten Vorhersagen zu Verhaltensänderungen liefern.

1.2 Zielsetzung

Ziel dieser Arbeit ist es, den Ansatz der vollständig modellbasierten Closed-Loop-Simulationen zu unterstützen. Die Vorhersage menschlichen Verhaltens bei der Interaktion mit neuen technischen Systemen mittels Simulationen ist dabei ein bereits bekanntes Vorgehen in der wissenschaftlichen Literatur. Ein prominentes Beispiel ist die CogTool-Software (John, 2011), die automatisch prädiktive menschliche Verhaltensmodelle erzeugt, basierend auf einer einfachen Beschreibung des User-Interfaces. Salvucci (2009) nutzte den CogTool-Ansatz für sein Distract-R-System, das Fahrverhaltensänderungen bei der Interaktion mit grafischen Nutzungsschnittstellen im Fahrzeug vorhersagt.

Ähnlich motiviert wie das Distract-R System zielt diese Arbeit darauf ab, zu untersuchen, ob der Einfluss neuer Fahrzeugsysteme auf die visuelle Aufmerksamkeitsverteilung der Fahrer ebenfalls durch einen softwarebasierten Simulationsansatz evaluiert werden kann. Anders als beim Distract-R System wird der Fokus in dieser Arbeit auf den Einfluss gelegt, den die Menge an Ereignissen, auf die der Fahrer reagieren muss, auf dessen visuelle Aufmerksamkeitsverteilung hat. Beim Autofahren beeinflusst die Zeitdauer, die der Fahrer nicht auf die Straße schaut, die Wahrscheinlichkeit von Unfällen essentiell (Klauer et al., 2006, 2010). Daher soll die Simulation der Aufmerksamkeit nicht nur plausible Durchschnittswerte wie die prozentuale Blickverteilung erzeugen, sondern auch die Blicksequenzen in kleinen Zeiträumen sinnvoll vorhersagen.

Auf diese Weise soll es möglich sein, mit dem Closed-Loop-Simulationsansatz eine größere Breite an Assistenz- und Infotainmentsystemen zu untersuchen. Insbesondere wird darauf abgezielt, auch teilautonome Assistenzsysteme zu untersuchen, die nicht über eine direkte Nutzerschnittstelle mit dem Fahrer interagieren, sondern vor allem implizit durch den Einfluss, den das Assistenzsystem auf das Fahrzeug hat. Beispiele hierfür sind ACC-Systeme oder aktive Spurhalteassistenten. Diese Systeme nehmen dem Fahrer Aufgaben ab und reduzieren damit auch die Menge an Informationen, auf die der Fahrer reagieren muss, da die nötige Reaktion nun durch das Assistenzsystem geschieht. Die Abgabe von Aufgaben an automatisierte Systeme ist nicht unkritisch, da dadurch Out-of-the-Loop-Probleme entstehen können (Endsley und Kaber, 1999).

Um solche Effekte vorherzusagen, wurde innerhalb dieser Arbeit das Adaptive Information Expectancy (AIE)-Modell entwickelt, das dazu dient, die Adaption der Aufmerksamkeitsverteilung an neue Fahrzeugsysteme zu simulieren. Das ist das Ziel dieser Arbeit. Um es zu erreichen, wurden eine Reihe verschiedener Schritte durchgeführt:

Theoretische Konzeptionierung Auf der Basis bereits bestehender Erkenntnisse und Modelle zur menschlichen Aufmerksamkeitsverteilung wurde ein generisches Konzept zur Simulation der Aufmerksamkeit entwickelt, das sich dynamisch an unterschiedliche Ereignisraten anpasst. Hierfür wurde einerseits der Stand der Forschung zur dynamischen Simulation der Aufmerksamkeit gesichtet. Andererseits wurden Studien zusammengetragen, die den Einfluss von Ereignisraten auf die menschliche Aufmerksamkeit untersuchen. Die gesammelten Ergebnisse sind schließlich in einem Konzept für ein dynamisches Simulationsmodell integriert worden: dem AIE-Modell. Eine Haupthypothese, die dem Simulationsmodell zugrunde liegt, ist in ähnlicher Form auch Grundlage zahlreicher Studien in der Literatur (vgl. z. B. (Horrey et al., 2005), (Miller et al., 2004)). Sie besagt:

Je mehr Ereignisse in einer Informationsquelle auftreten, auf die der Fahrer reagieren muss, desto mehr Aufmerksamkeit richtet der Fahrer auf diese Informationsquelle.

Integration in ein Simulationsframework Um in der Praxis mit diesem theoretischem Aufmerksamkeitsmodell Simulationen durchführen zu können, muss es in ein geeignetes Simulationsframework eingebettet werden, das in der Lage ist, alle für das Modell benötigten Informationen bereitzustellen. Daher wurde das Aufmerksamkeitsmodell repräsentativ in eine kognitive Architektur integriert, die eben ein solches Simulationsframework darstellt.

Evaluation des Aufmerksamkeitsmodells Das Aufmerksamkeitsmodell wurde in zwei Schritten evaluiert. Die erste Evaluation wurde anhand einer Laboraufgabe durchgeführt, die speziell den Einfluss von Ereignisraten auf die Aufmerksamkeitsverteilung untersucht. Dadurch lässt sich das Aufmerksamkeitsmodell mit nur wenigen Störeinflüssen untersuchen. Da reale Situationen jedoch in der Regel komplexer sind, wurde in einem zweiten Schritt das Modell in einer anwendungsnäheren Situation untersucht werden. Dies geschah anhand einer Fahraufgabe in einem realistischen Fahrsimulator. Für beide Aufgaben muss jeweils ein kognitives Modell entwickelt werden, mit dem die Bearbeitung der jeweiligen Aufgabe simuliert werden kann. Die Simulation der Aufmerksamkeit erfolgt dabei durch das neu entwickelte AIE-Modell.

Essentiell für die Evaluierung des Aufmerksamkeitsmodells ist der Vergleich der Modellvorhersagen mit dem Verhalten von realen Personen bei der Bearbeitung der beiden Aufgaben. Für die Laboraufgabe wurde hierfür auf empirische Daten aus der Literatur zurückgegriffen. Für die Fahraufgabe wurde dagegen eine geeignete empirische Studie entwickelt und durchgeführt. Dabei wurde zuerst die oben genannte Hypothese geprüft und anschließend wurde das Modellverhalten mit den experimentellen Daten verglichen.

Die drei beschriebenen Schritte sind typisch für computergestützte Modellierungsprozesse und sind in Abbildung 1.2 in allgemeiner Form nach Sargent (2005) dargestellt. Dort sind auch die drei Sichten auf das zu modellierende System zu sehen. Dies ist zum einen das reale, zu modellierende System selbst (Problementität). Zum anderen das konzeptionelle Modell und schließlich die Implementierung des konzeptionellen Modells als ein computerbasiertes Simulationsmodell.

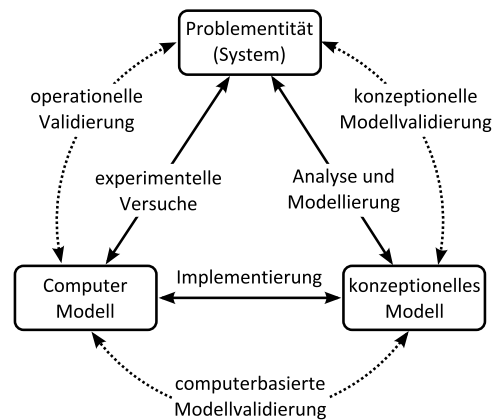


Abbildung 1.2 – Typische Schritte im Modellierungsprozess nach Sargent (2005).

1.3 Publikationen

Einige Aspekte der hier vorgestellten Arbeit wurden bisher in vier Publikationen veröffentlicht:

- Das AIE-Modell wurde erstmalig veröffentlicht auf der sechsten *International Conference on Advances in Computer-Human Interaction* (Wortelen und Lüdtke, 2013). Die Veröffentlichung präsentiert zudem einige Ergebnisse der Evaluation anhand einer einfachen Laboraufgabe.
- Die zentralen Ergebnisse, die bei der Evaluierung der visuellen Aufmerksamkeitsverteilung anhand der Fahrsimulatorstudie erzielt wurden, wurden im *Journal Transportation Research Part F: Traffic Psychology and Behaviour* veröffentlicht (Wortelen et al., 2013a).
- Mittels derselben Studie wurde eine explorative Analyse des Fahrverhaltens des Fahrermodells unter Verwendung des AIE-Modells im Vergleich zum Fahrverhalten der Versuchspersonen durchgeführt. Diese Ergebnisse wurden auf der 22. *Conference on Behavior Representation in Modeling & Simulation (BRiMS)* präsentiert (Wortelen et al., 2013b).
- In einem Beitrag zur 12. *International Conference on Cognitive Modeling (ICCM)* wurden schließlich die Modellanpassungsgüten von zwei Modellvarianten des AIE-Modells anhand der Fahrsimulatorstudie diskutiert (Wortelen et al., 2013c).

1.4 Aufbau der Arbeit

Im nun folgenden Kapitel 2 werden die für diese Arbeit benötigten Grundlagen des AIE-Modells sowie der aktuelle Stand der Forschung im direkten thematischen Umfeld der Arbeit vorgestellt. Es wird insbesondere auf eine Reihe von Modellen der menschlichen Aufmerksamkeitsverteilung eingegangen, da auf dieser Basis das Konzept des AIE-Modells erstellt wird. Zudem werden verschiedene Ansätze zur Modellierung menschlichen Verhaltens mittels kognitiver Architekturen dargestellt. Dabei wird ein besonderes Augenmerk auf die kognitive Architektur CASCaS

(Cognitive Architecture for Safety Critical Task Simulation) gelegt, da sie das Rahmenwerk bildet, in das das AIE-Modell zu Evaluationszwecken implementiert wird. Im dritten Kapitel wird schließlich das konzeptionelle AIE-Modell vorgestellt. Dabei wird zuerst auf die Art der Aufgaben eingegangen, bei denen das AIE-Modell von Nutzen sein kann. Nachfolgend werden die Struktur und Arbeitsweise des Modells vorgestellt und anschließend diskutiert. Das Kapitel schließt mit einer Beschreibung der Integration und Implementierung des computergestützten AIE-Modells in CASCaS.

In den Kapiteln 4 und 5 wird das AIE-Modell anhand zweier Studien evaluiert. Für die erste Studie (Kapitel 4) wird die Aufmerksamkeitsverteilung für eine einfache, fokussierte Laboraufgabe vorhergesagt. Die zweite Studie (Kapitel 5) ist dagegen komplexer, aber auch anwendungsnäher und betrifft die Aufmerksamkeitsverteilung beim Autofahren in einer simulierten Verkehrsumgebung. Zur operationellen Validierung des Modells wird das AIE-Modell in beiden Fällen genutzt, um die Aufmerksamkeitsverteilung in einer dynamischen Simulation vorherzusagen. Zudem werden für die konzeptionelle Modellvalidierung diese Studien genutzt, um einige Parameter des Modells zu diskutieren und um Vergleiche zwischen verschiedenen Modellvarianten sowie Vergleiche zu einem existierenden Aufmerksamkeitsmodell aus der Literatur zu ermöglichen.

In Kapitel 6 werden schließlich die erzielten Ergebnisse zusammengefasst und diskutiert. Zudem werden offene Punkte für zukünftige Arbeiten identifiziert.

Kapitel 2

Grundlagen und Stand der Forschung

In dieser Arbeit wird ein Modell der menschlichen Aufmerksamkeitsverteilung entwickelt, das innerhalb einer kognitiven Architektur Verwendung findet und schließlich für die Entwicklung eines kognitiven Fahrermodells genutzt wird. Hierzu werden in diesem Kapitel die thematischen Grundlagen und der aktuelle Stand der Forschung vorgestellt.

Die Evaluation des in dieser Arbeit entwickelten Aufmerksamkeitsmodells wird vornehmlich über den Vergleich von menschlichem Blickverhalten und modellgeneriertem Blickverhalten vorgenommen. Daher werden zuerst kurz einige Grundlagen der menschlichen visuellen Wahrnehmung und der Zusammenhang zwischen Blickverhalten und Aufmerksamkeit erläutert. Ebenso werden wichtige Maße des Blickverhaltens vorgestellt.

Anschließend wird der Begriff der Aufmerksamkeit näher beleuchtet und es wird eine Begriffsdefinition für diese Arbeit gegeben. Aus dem breiten Repertoire menschlicher Aufmerksamkeitsmodelle werden schließlich diejenigen vorgestellt, die als Basis für das hier entwickelte Modell dienen oder einen engen Bezug zum AIE-Modell haben.

In Abschnitt 2.2 wird auf die Modellierung menschlichen Verhaltens mittels kognitiver Architekturen eingegangen. Einige für diese Arbeit interessante Architekturen werden kurz vorgestellt. Die kognitive Architektur CASCaS wird detaillierter beschrieben (Abschnitt 2.3), da sie das Rahmenwerk bildet, in das das AIE-Modell zu Evaluationszwecken integriert wird. Zum Abschluss wird in Abschnitt 2.4 ein sehr kurzer Überblick über verschiedene Möglichkeiten der Fahrermodellierung gegeben und Beispiele existierender Fahrermodelle aufgezeigt.

2.1 Blickverhalten und Aufmerksamkeit

Der Mensch lässt sich als eine Art informationsverarbeitende Maschine auffassen. Er nimmt Informationen auf, verarbeitet sie und agiert basierend auf diesen Informationen. In vielen Situationen hängt die Güte des menschlichen Handelns essentiell davon ab, wie gut der Mensch in der Lage ist, die für ihn wichtigen Informationen aus seiner Umgebung aufzunehmen. Eine solche Situation ist zum Beispiel das Autofahren. Der Fahrer bewegt sich vergleichsweise schnell durch seine Umgebung. Dadurch ändert sich sein direktes Umfeld ständig und er muss fortwährend nach

wichtigen, neuen Informationen, wie z.B. Fußgängern oder Verkehrsschildern, Ausschau halten.

Informationen kann er dabei über verschiedene Sinneskanäle wahrnehmen. Im allgemeinen Sprachgebrauch werden der menschlichen Wahrnehmung üblicherweise fünf Sinne zugeordnet:

- Sehen (Visuelle Wahrnehmung),
- Hören (Auditive Wahrnehmung),
- Riechen (Olfaktorische Wahrnehmung),
- Schmecken (Gustatorische Wahrnehmung) und
- Tasten (Haptische Wahrnehmung).

Zudem nennt die Physiologie ein Reihe weiterer bewusst und unbewusst wahrgenommener Sinne, wie z.B. Gleichgewichtssinn (Vestibulärsinn) und Temperatursinn (Thermorezeption) (Seeley et al., 2003, Kap. 14, 15). In vielen Umgebungen werden jedoch die meisten Informationen über den Sehsinn wahrgenommen. Er spielt daher eine besondere Rolle. Dies ist auch beim Autofahren der Fall. Typische Schätzungen gehen davon aus, dass etwa 80-90 % der beim Fahren verwendeten Informationen über die visuelle Wahrnehmung aufgenommen werden (Abendroth und Bruder, 2009; Wheatley, 2001). Über den vestibulären, haptischen oder akustischen Sinneskanal können zwar einige Informationen zum Zustand des Fahrzeuges (z.B. Geschwindigkeit oder Längs- und Querbewegung) wahrgenommen werden (Schweigert, 2003), jedoch ermöglicht es nur der Sehsinn, ein ausreichendes mentales Bild der Umgebung zu erzeugen. Dies zeigt sich gut bei Fahrsimulatoren mit statischer Fahrerkabine, die sich nicht auf einer bewegten Plattform befindet. Auch in diesen Simulatoren sind die Fahrer in der Lage unfallfrei zu fahren, obwohl sämtliche Informationen aus den vestibulären, haptischen und z. T. akustischen Sinneskanälen fehlen.

Wie in vielen sicherheitskritischen Umgebungen ist es auch beim Autofahren wichtig, alle relevanten Informationen zu erhalten, um die richtigen Entscheidungen zu treffen. Es ist daher nicht erstaunlich, dass sich viele Arbeiten mit der Thematik der menschlichen Wahrnehmung und insbesondere der visuellen Wahrnehmung beschäftigen. Das beginnt mit grundlegenden Fragestellungen zum visuellen System. Hier sind es vor allem biologische Faktoren wie die Verteilung der Rezeptorzellen - den sogenannten Stäbchen und Zapfen - auf der Netzhaut (Retina) (s. Abbildung 2.1), der wahrnehmbare Bereich des Lichtes oder auch die Akkomodationsfähigkeit (Anpassung der Augenlinse an die Sehentfernung), die eine Rolle für die Informationsaufnahme spielen (Abendroth und Bruder, 2009).

Die Dichte der Stäbchen, die vor allem für die Helligkeitswahrnehmung zuständig sind, nimmt mit zunehmender Exzentrizität zur Fovea zu, während umgekehrt die Anzahl der Zapfen, die die Wahrnehmung von Farben ermöglichen, in Richtung der Fovea zunimmt. Die Fovea selbst beinhaltet nur Zapfen. Die Wahrnehmung unterscheidet sich daher stark in den verschiedenen Bereichen der Retina. Man unterscheidet die **foveale Wahrnehmung** (Informationsaufnahme innerhalb der Fovea) und die **periphere Wahrnehmung** (Informationsaufnahme außerhalb der Fovea) (Seeley et al., 2003, Kap. 15). Neben dieser örtlichen Unterscheidung wird meistens eine funktionale Differenzierung zwischen dem **fokalen (ventral)** und dem **ambienten (dorsal) Sinneskanal** vorgenommen (Schieber et al., 2009). Die fokale

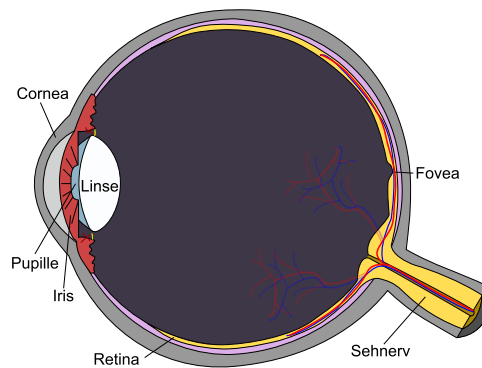


Abbildung 2.1 – Schematische Darstellung des menschlichen Auges. (Quelle: Public Domain, Wikimedia)

Wahrnehmung ist zuständig für Muster- und Detailwahrnehmung und erhält Informationen fast ausschließlich aus der Fovea. Die ambiente Wahrnehmung ist dagegen vor allem zuständig für die Wahrnehmung von Bewegung, insbesondere der eigenen Bewegung. Sie erhält Informationen aus allen Bereichen der Retina. Ihre Fähigkeit nimmt nur geringfügig mit der Entfernung zur Fovea ab. Beim Autofahren wird vor allem die **Lateralkontrolle**, also das Führen des Fahrzeugs innerhalb der Fahrspur, durch die ambiente Wahrnehmung unterstützt (Summala et al., 1996; Schieber et al., 2009). Die Erkennung von potentiellen Gefahren und die **Longitudinalkontrolle**, also das Einhalten eines konstanten Abstandes, benötigen dagegen die fokale Wahrnehmung (Summala et al., 1998; Horrey et al., 2005; Lenneman et al., 2009). Aus den Rohinformationen der Rezeptoren extrahiert das Gehirn schließlich höherwertige Informationen, wie Konturen und Formen, Anordnung und Position sowie Größe und Ausrichtung von Formen, Bewegungen und Texturen. Auch die Informationsextraktion wird vor allem durch die biologischen Faktoren beeinflusst. Beim Autofahren spielen hier zum Beispiel alters- oder krankheitsbedingte Veränderungen in der Kontrastwahrnehmung, der Sehschärfe oder der Sicht bei Dämmerung eine Rolle (Kotecha et al., 2008; Group, 2005).

Im Zusammenhang mit dieser Arbeit ist bei der Extraktion von Merkmalen die Unterteilung in **präattentive** und **attentive** Merkmale von Interesse. Präattentive Merkmale werden automatisch, unbewusst, parallel und ohne mentalen Aufwand wahrgenommen (Treisman, 1985). Dies bedeutet insbesondere, dass die Aufmerksamkeit nicht auf diese Merkmale gerichtet werden muss, sofern sie momentan im visuellen Feld wahrnehmbar sind. Auch die Bewegungswahrnehmung des ambienten Sinneskanals erfolgt vor allem präattentiv (Lenneman et al., 2009). Dieser Aspekt wird später bei der Beschreibung des Fahrermodells erneut aufgegriffen.

Im Bereich der Informationsextraktion existieren viele Studien und Modelle (z. B. (Theeuwes, 1994), (Eriksen und Hoffman, 1973)), die beschreiben, wie Merkmale aus dem visuellen Eindruck der Umgebung identifiziert werden. In diesem Themenbereich lassen sich Fragestellungen einordnen, wie:

- Welche Farbunterschiede werden noch wahrgenommen?
- Wie werden 3D-Informationen aus dem visuellen Eindruck extrahiert?
- Wie lange benötigt die Wahrnehmung dieser Merkmale?

Auch beim Autofahren haben diese Aspekte eine gewisse Relevanz. Wichtige Informationen für den Fahrer, wie z.B. Gefahrenschilder, werden meist sehr kontrastreich präsentiert, um eine Objektidentifizierung zu erleichtern. Der Aspekt der Informationsextraktion wird im weiteren Verlauf jedoch nicht näher betrachtet. Zur Vereinfachung wird stets davon ausgegangen, dass alle Informationen im visuellen Fokus und alle präattentiven Informationen im **peripheren Wahrnehmungsfeld** perfekt extrahiert werden.

Ein weiterer Aspekt der menschlichen Informationswahrnehmung ist schließlich die aktive Suche nach Informationen. Durch Augen- und Kopfbewegung ist der Mensch in der Lage, gezielt nach Informationen an verschiedenen Stellen in seiner Umgebung Ausschau zu halten.

Das menschliche Blickverhalten hat für diese Arbeit eine sehr große Bedeutung, da zwischen Aufmerksamkeit und Blickzuwendung ein enger Zusammenhang besteht. Einerseits richten Menschen typischerweise ihren Blick auf Dinge, auf die sie auch mental ihre Aufmerksamkeit gerichtet haben (**endogene Aufmerksamkeitskontrolle**, engl.: top-down attention) (Theeuwes, 1991). Andererseits rücken auffällige Informationen, die in das Blickfeld gelangen, meist automatisch auch in den Fokus der Aufmerksamkeit (**exogene Aufmerksamkeitskontrolle**, engl.: bottom-up attention) (Theeuwes, 1991).

2.1.1 Messung der Augenbewegungen

Das menschliche Blickverhalten kann auf verschiedene Weisen charakterisiert werden. Dabei werden verschiedene Bezeichnungen verwendet, die nicht einheitlich definiert sind. Grundlage für die Bezeichnung der Blickbewegungsparameter, die in dieser Arbeit Verwendung finden, ist die ISO 15007-1:2002 (ISO, 2002). Diese Norm dient dem Zweck, die Darstellung der Ergebnisse von Eyetracking-Untersuchungen im Automobilbereich zu vereinheitlichen. Primär wird dies für die Untersuchung von Fahrerassistenz- und Informationssystemen benötigt. In diesem Abschnitt werden nun einige Maße vorgestellt, die innerhalb der Arbeit verwendet werden. Für eine weiterführende Auflistung sei auf die Norm selbst (ISO, 2002) und Josephson (2004) verwiesen.

Das Blickverhalten besteht hauptsächlich aus einer Abfolge von Fixationen und Sakkaden. **Fixationen** sind Zeitabschnitte, in denen sich der Blick mit geringer Geschwindigkeit innerhalb eines sehr kleinen Bereichs befindet. **Sakkaden** sind dagegen Abschnitte, in denen sich der Blick mit hoher Geschwindigkeit von einem Fixationsbereich zu einem anderen bewegt. Die Größe einer Blickbewegung wird häufig in Winkelgrad gemessen, wobei das Augenzentrum als Bezugspunkt dient. Heutige kommerzielle Eyetracking-Systeme weisen bei der Blickrichtungsmessung eine sehr hohe Qualität auf. Es werden üblicherweise Genauigkeiten von bis zu 0.5° erreicht¹. Neben den Sakkaden gibt es noch weitere Arten von Augenbewegungen wie zum Beispiel gleichmäßige Verfolgungsbewegungen (smooth pursuit), die auftreten wenn Objekte mit dem Blick verfolgt werden (Land und Tatler, 2009).

Viele Studien zum Blickverhalten gehen davon aus, dass ein sehr starker Zusammenhang besteht zwischen dem Gegenstand, der gerade fixiert wird, und dem, was mental verarbeitet wird. Grundlegende Ideen hierzu stellten u. a. Just und Carpenter (1976) auf. Später formulierten sie dies expliziter in zwei Annahmen, die heute sehr vielen Eyetracking-Studien zugrunde gelegt werden (Just und Carpenter, 1980):

¹Herstellerangaben unter Idealbedingungen. Siehe z.B.: Tobii Technology (<http://www.tobii.com>) oder Sensomotoric Instruments (<http://www.smivision.com>).

Eye-Mind-Annahme:

Ziel einer Blickfixation ist der Gegenstand bzw. das Symbol, das zurzeit mental verarbeitet wird.

Immediacy-Annahme:

Die Fixationsdauer entspricht der Verarbeitungsdauer.

Bei Voraussetzung der Eye-Mind-Annahme lassen sich Bereiche und Informationen identifizieren, die für den Menschen bei der Bearbeitung einer Aufgabe relevant sind. Auf Basis der **Immediacy-Annahme** lassen sich dagegen Rückschlüsse auf die Komplexität der wahrgenommenen Informationen schließen.

Dafür müssen jedoch erst einmal die Fixationen und Sakkaden in den aufgenommenen Daten des Eyetrackers identifiziert werden. Zur Klassifikation von Sakkaden und Fixationen in einer Messreihe können eine Reihe von Verfahren angewendet werden. Gängige Verfahren nutzen Grenzwerte für Blickgeschwindigkeiten oder Bereichsgrößen, um zwischen Fixationen und Sakkaden zu unterscheiden. Gute Ergebnisse lassen sich auch mit der Nutzung von Hidden-Markov-Modellen zur Klassifikation erzielen. Eine Übersicht und Bewertung verschiedener Verfahren findet sich zum Beispiel bei [Salvucci \(1999\)](#).

Ein weiteres Verfahren zur Bestimmung von Blicken und Blickbewegungen, das vergleichsweise einfach durchzuführen ist und auch sehr häufig Verwendung findet, ist das Zielgebietsverfahren ([Salvucci und Goldberg, 2000](#)). Die Verwendung dieses Verfahrens wird auch von der ISO 15007 erwartet. Es findet zudem in den in Kapitel 4 und 5 beschriebenen Experimenten Verwendung. Hierbei werden vor der Untersuchung Bereiche festgelegt, die dem Menschen als Informationsquelle dienen, sogenannte **Areas of Interest (AOIs)**. Die Grundidee des Verfahrens ist, dass alle aufeinanderfolgenden Blickpunkte, die in das selbe AOI gerichtet sind, einem Blick zugeordnet werden. Alle Blickpunkte, die auf kein AOI treffen, werden nicht betrachtet. Dieses Verfahren ist zwar einfach anzuwenden, hat aber auch einige Nachteile. So wird mit diesem Verfahren prinzipiell keine Unterteilung in Fixationen und Sakkaden vorgenommen. Die Diskriminierung dieser Konzepte müsste auf Basis der Geschwindigkeit der Augenbewegung geschehen. Das Zielgebietsverfahren liefert dagegen eine Sequenz von Blicken auf die beteiligten AOIs, wobei ein Blick aus mehreren Fixationen bestehen kann.

Definition 1 (Blick)

In dieser Arbeit wird ein Blick als die aufeinanderfolgenden Fixationen zur gleichen Informationsquelle verstanden. Dies entspricht der ISO 15007-1 Definition (ISO, 2002) des Wortes glance.

Definition 2 (Transition)

Da beim Zielgebietsverfahren die Sakkaden innerhalb eines AOI nicht berücksichtigt werden, wird auch die Blickbewegung von einem AOI zu einem anderen nicht als Sakkade, sondern als Transition (ISO, 2002) bezeichnet.

Ein Problem des Zielgebietsverfahren besteht darin, dass bei der Definition der AOIs bereits Ad-hoc-Annahmen darüber gemacht werden, welche Informationsquellen der Mensch verwenden wird. Schlecht gewählte AOIs können daher die Ergebnisse verfälschen. Dennoch wird dieses Verfahren gerade auch im Bereich der Validierung kognitiver Modelle gerne angewendet, da auch kognitive Modelle häufig Ad-hoc-Annahmen zu Informationsquellen machen, die für die Bearbeitung einer Aufgabe relevant sind. Werden für die Versuche mit menschlichen Probanden die

gleichen AOIs gewählt, wie für das Modell, so lassen sich die Modelldaten einfach mit den Experimentaldaten vergleichen. Aufgrund der verfälschenden Wirkung durch fehlerhafte Annahmen zu den AOIs sollte dieses Vorgehen jedoch mit Bedacht gewählt werden.

Möbus et al. (2011a) stellten einen Ansatz vor, mit dem die Identifizierung der relevanten Informationsquellen systematisch durch empirische Studien unterstützt werden kann, ohne dass Daten eines Eyetrackers benötigt werden. Dabei werden Daten des Nutzerverhaltens aus empirischen Studien verwendet, um mit statistischen Lernverfahren zu untersuchen, welche Variablen gut geeignet sind, das Nutzerverhalten vorherzusagen. Wird ein starker statistischer Zusammenhang zwischen den Ausprägungen einer Variablen und dem Nutzerverhalten festgestellt, so kann erwartet werden, dass der Nutzer seine Aufmerksamkeit auf eine Informationsquelle richtet, in der die Variablenausprägung wahrnehmbar ist. Ein Vorteil dieses Verfahrens ist, dass prinzipiell auch Informationen berücksichtigt werden können, die über das **periphere Wahrnehmungsfeld** wahrgenommen werden. Dies ist mit Eyetrackerstudien schwieriger zu ermitteln. Zudem lassen sich so Hypothesen zur Relevanz einer Informationsquelle empirisch fundieren.

2.1.2 Maße und Bedeutung des Blickverhaltens

Für Eyetrackerstudien lassen sich auf Basis der ermittelten Blicke und Transitionen verschiedene Maße des Blickverhaltens bestimmen. Es werden im Folgenden die Maße beschrieben, die während der durchgeführten Evaluationen in Kapitel 4 und 5 zur Charakterisierung des Blickverhaltens verwendet wurden.

2.1.2.1 Prozentuale Blickverweilzeit

Ein häufig genutztes Maß, um die Menge an visueller Aufmerksamkeit zu beschreiben, die eine Informationsquelle erhält, ist die prozentuale Blickverweilzeit (engl.: Percentage Dwell Time (PDT)). Sie gibt den Zeitanteil innerhalb eines definierten Zeitraums an, den der Blick auf die Informationsquelle gerichtet ist.

2.1.2.2 Blickfrequenz und Blickdauer

Die prozentuale Blickverweilzeit setzt sich aus zwei Aspekten zusammen: der Blickfrequenz innerhalb des betrachteten Zeitraums und der durchschnittlichen Blickdauer. Nach Moray (1986, S. 40(22)) setzte sich das Blickverhalten aus zwei Mechanismen zusammen. Den Mechanismus, der bestimmt, wohin der nächste Blick gerichtet wird, bezeichnet Moray als **Ablaufplanungsalgorithmus**. Er ist maßgeblich dafür verantwortlich, mit welcher Frequenz der Blick auf eine Informationsquelle gerichtet wird. Den Mechanismus, der die Dauer des Blickes bestimmt, bezeichnet Moray dagegen als **Datenakquisealgorithmus**. Er geht davon aus, dass die Blickdauer unter anderem die Schwierigkeit der Informationsaufnahme charakterisiert. Die Argumentation folgt dabei der Immediacy-Annahme, dass die Fixationsdauer vor allem durch die Zeit bestimmt wird, die der Mensch zur Verarbeitung der Informationen benötigt (Just und Carpenter, 1980). Das beinhaltet nicht nur die Wahrnehmung der physikalischen Erscheinung der Information und das Kodieren dieser, sondern auch das semantische Verständnis der Information. Die Immediacy-Annahme bezieht sich jedoch auf die Dauer von Fixationen und nicht auf die Dauer von Blicken. Ein Blick zu einer Informationsquelle kann aus mehreren Fixationen innerhalb der Informationsquelle bestehen.

In Situationen, in denen der Blick nicht mit anderen Aktionen koordiniert werden muss, lässt sich diese Annahme dennoch gut vertreten. Typische Beispiele im Automobilbereich sind das Erkennen von Verkehrsschildern oder das Ablesen der Geschwindigkeits- oder Tankanzeige. Die Aktionen, die auf Basis der wahrgenommenen Informationen durchgeführt werden müssen, können durchgeführt werden, ohne dass der Blick weiterhin auf die entsprechende Informationsquelle gerichtet ist. Daher ist es plausibel anzunehmen, dass in diesen Fällen die Blickdauer tatsächlich nur der Dauer entspricht, die zum Ablesen der Informationen benötigt wird. Dies führt zu relativ kurzen Blicken, die typischerweise aus nur einer oder sehr wenigen Fixationen bestehen. In vielen Situationen ist das Blickverhalten jedoch dadurch geprägt, dass eine Koordination von Blick und Aktionen nötig ist (Land und Tatler, 2009). Die Länge eines Blickes hängt dabei stark von der Art und Schwierigkeit der Aufgabe ab. Beim Autofahren ist eine solche Koordination zum Beispiel wichtig für das Spurhalten oder die Kollisionsvermeidung. Dazu wird der Blick so lange auf die Straße oder das vorausfahrende Fahrzeug gerichtet, wie es nötig ist, um das Fahrzeug in einem sicheren Zustand zu stabilisieren. Die Blickdauer ist daher nicht nur durch die Schwierigkeit der Informationsaufnahme, sondern auch durch die Anforderungen der jeweiligen Aufgabe bestimmt. Die Experimente, die in dieser Arbeit zur Evaluierung des AIE-Modells herangezogen wurden, wurden jeweils mit dem Zielgebietsverfahren ausgewertet. Da insbesondere im Fahrsimulatorexperiment (Kapitel 5) die angesprochene Koordination von Blick und Aktionen eine Rolle spielt, wird in dieser Arbeit lediglich die Eye-Mind-Annahme vorausgesetzt.

2.1.2.3 Transitionswahrscheinlichkeit

Die Untersuchung von Transitionen liefert ein weiteres Maß des Blickverhaltens, das für das Design von Mensch-Maschine-Schnittstellen hilfreich ist. Es ist sinnvoll Informationsquellen, die meistens direkt nacheinander betrachtet werden, nah beieinander zu platzieren (Fitts und Simon, 1952). Daher werden Transitionswahrscheinlichkeiten untersucht, um die Güte der Anordnung von Anzeigeelementen zu untersuchen (z. B.: (Barnes, 1972), (Fitts et al., 1949)). Die Transitionswahrscheinlichkeit $p_{i,j}$ wird in ISO 15007-1 als Link Value Probability bezeichnet und beschreibt die relative Häufigkeit, dass ein Blick zwischen den Informationsquellen i und j wechselt. Dabei fasst $p_{i,j}$ Transitionen von i zu j und von j zu i zusammen. Soll nur eine Richtung berücksichtigt werden, so wird von einer gerichteten Transitionswahrscheinlichkeit $p_{i \rightarrow j}$ von i nach j gesprochen. Aus experimentellen Eyetrackingdaten werden $p_{i \rightarrow j}$ und $p_{i,j}$ ermittelt durch (ISO, 2002):

$$p_{i \rightarrow j} = \frac{n_{i,j}^T}{\sum_{k,l \in AOI} n_{k,l}^T}, \quad \text{und} \quad p_{i,j} = p_{j,i} = p_{i \rightarrow j} + p_{j \rightarrow i} \quad (2.1)$$

Dabei bezeichnet AOI die Menge aller betrachteten Informationsquellen und $n_{i,j}^T$ die absolute Anzahl an Transitionen von Informationsquelle i zu Informationsquelle j im betrachteten Zeitraum.

2.1.2.4 Blickablenkungsdauer

Bei der Untersuchung des Blickverhaltens von Autofahrern ist nicht nur die Frage interessant, wie oft und wie lange der Blick auf eine Informationsquelle gerichtet ist, sondern auch wie lange er nicht auf sie gerichtet ist. Dies wird als Blickablenkungsdauer bezeichnet. Nach ISO 15007:1 (*Duration of diversion*) wird sie gemessen von

dem Zeitpunkt, an dem der Blick die Informationsquelle verlässt, bis zum Zeitpunkt, an dem er zum ersten Mal wieder auf die Informationsquelle gerichtet ist. Diese Zeitspanne ist beim Autofahren von besonderem Interesse, da die Blickablenkungsdauer zur Straße und dem umgebenden Verkehr maßgeblich die Reaktionszeit bestimmt (Summala et al., 1998).

2.1.3 Aufmerksamkeit

Das Messen und Charakterisieren des Blickverhaltens spielt bei vielen Untersuchungen des menschlichen Verhaltens eine essentielle Rolle, da es, basierend auf der Eye-Mind-Annahme, häufig Rückschlüsse auf die internen Verarbeitungsschritte des Menschen zulässt. Diese Annahme wird in Kapitel 4 und 5 auch bei der Interpretation der Blickdaten verwendet, die zur Evaluation des AIE-Modells herangezogen werden. Es wird davon ausgegangen, dass über die Blicke identifiziert werden kann, worauf die Versuchsperson momentan ihre Aufmerksamkeit richtet. Intuitiv besitzt man eine Vorstellung davon, was Aufmerksamkeit ist, und dass man sie auf etwas richten kann. Da Aufmerksamkeit ein zentraler Begriff in dieser Arbeit ist und für die Erstellung des AIE-Modell ein klares Verständnis des Begriffs nötig ist, werden an dieser Stelle verschiedene Definitionen von Aufmerksamkeit aus der Literatur aufgezeigt, um schließlich eine Definition von Aufmerksamkeit geben zu können, so wie sie für die weitere Arbeit verwendet wird.

Die Aufmerksamkeit ist ein wichtiger Aspekt des menschlichen Handelns und hat viele unterschiedliche Facetten. Wie bei einigen anderen Begriffen in der Kognitionspsychologie wie z. B. dem *Situationsbewusstsein* oder der *mentalen Auslastung* ist es auch für den Begriff der Aufmerksamkeit schwierig eine klare Definition zu geben. In der Literatur finden sich zahlreiche Definitionen, die versuchen die Aufmerksamkeit kurz und prägnant verbal zu beschreiben. Dabei wird der Fokus jeweils auf unterschiedliche Facetten der Aufmerksamkeit gelegt.

Eine wichtige Facette der Aufmerksamkeit ist ihre Funktion, aus der großen Menge an Sinneseindrücken einige wenige auszuwählen, die mental weiter verarbeitet werden. Rizzolatti et al. (1994) sehen vor allem diesen auswählenden Charakter der Aufmerksamkeit:

To attend is to select for further processing.

(Rizzolatti et al., 1994, S.232)

Desimone und Duncan (1995) betrachten Aufmerksamkeit aus Sicht der Neurowissenschaft als eine Eigenschaft, die sich aus dem Zusammenspiel neuraler Mechanismen herausbildet:

[...] *attention is an emergent property of many neural mechanisms working to resolve competition for visual processing and control of behavior.*

(Desimone und Duncan, 1995, S.194)

Auch ihre Definition beschreibt die Funktion der Aufmerksamkeit damit, eine Auswahl zwischen konkurrierenden Informationen zu treffen. Dabei wird eine häufig vorgenommene Unterteilung gemacht zwischen der Auswahl von visuellen Informationen und der Auswahl von Verhaltensweisen. Man spricht hier auch von *visueller* und *mentaler Aufmerksamkeit*, oder sensorischer und intellektueller Aufmerksamkeit (James, 1890). Eine Metapher, die sich in diesem Zusammenhang öfters in der Literatur finden lässt und gut die Ähnlichkeit der beiden Begrifflichkeiten wiedergibt, ist die Bezeichnung der mentalen Aufmerksamkeit als "*The mind's eye*" (Gehring et al., 2003).

Das Lexikon der Neurowissenschaft ([wissenschaft online, 2012](#)) gibt eine etwas allgemeinere Unterteilung:

Aufmerksamkeit, *E attention, allgemeine Bezeichnung für einen Zustand der gesteigerten Wachheit (Vigilanz) und Anspannung, welcher der selektiven Orientierung von Wahrnehmung, Denken und Handeln zugrunde liegt [...].*
([wissenschaft online, 2012](#))

Bei dieser Definition werden mit der Wahrnehmung, dem Denken und dem Handeln gleich drei Aspekte genannt. Beim Wahrnehmungsaspekt geht es nicht nur um die Auswahl visueller Reize sondern generell um die Auswahl aus wahrgenommenen Stimuli. Diese Generalisierung wird nur selten vorgenommen. Die Ausrichtung der visuellen Aufmerksamkeit ist ein Konzept, das den meisten Menschen intuitiv leichter verständlich ist, bedingt dadurch, dass sie meist identisch ist mit der Ausrichtung des Blicks. Die fokussierte Selektion von Stimuli lässt sich jedoch auch bei einigen anderen Sinnen, wie zum Beispiel dem Hören, beobachten ([Shinn-Cunningham, 2008](#)). Die mentale Aufmerksamkeit ist bei dieser Definition etwas enger gefasst und mit der Orientierung des Denkens verknüpft — also der Kognition im engen Sinne. Sie ist von den motorischen Aktionen des Handelns getrennt (motorische Aufmerksamkeit). Im Fokus dieser Definition steht jedoch, dass die Aufmerksamkeit eine Größe ist, die unterschiedlich stark ausgeprägt sein kann und mit dem Grad an Bewusstsein in Verbindung gebracht wird.

Dieser Aspekt wurde ähnlich bereits sehr früh von [James \(1890\)](#) angesprochen.

Focalization, concentration, of consciousness are of its [attention] essence. It implies withdrawal from some things in order to deal effectively with others, and is a condition which has a real opposite in the confused, dazed, scatter-brained state.
([James, 1890, S.75](#))

Der Zweck der Aufmerksamkeit besteht demnach in der Ausführung effektiver, zielgerichteter Gedankengänge, was im Gegensatz zu ungeordneten Gedanken steht. In der Fachliteratur wird meistens jedoch von knappen Formulierungen abgesehen und eine ausführliche Differenzierung zu anderen Prozessen und Eigenschaft der Kognition vorgenommen.

Es lassen sich nun einige zentrale Punkte identifizieren, die die meisten Definitionen und Modelle gemeinsam haben. So wird typischerweise davon ausgegangen, dass der Mensch zum Bearbeiten seiner Aufgaben nur eine begrenzte Menge an Ressourcen hat. Welche Aufgabe nun die nötigen Ressourcen zugewiesen bekommt, bestimmt, worauf die Aufmerksamkeit gerichtet ist. Es wird daher häufig davon gesprochen, dass die Aufmerksamkeit auf eine Aufgabe gerichtet ist. Allerdings existieren unterschiedliche Sichten darauf, ob die Aufmerksamkeit gleichzeitig auf mehrere Aufgaben verteilt sein kann, oder nicht:

Bei einfachen Simulationsmodellen von Multitasking-Situationen wird in der Regel davon ausgegangen, dass immer nur eine einzelne Aufgabe gleichzeitig bearbeitet wird (z.B. [Aasmann, 1995](#); [Salvucci, 2005](#)). Der Umgang mit Multitasking-Situationen wird nun dadurch bewerkstelligt, dass häufig zwischen den Aufgaben gewechselt wird. Das Threaded Cognition Modell ([Salvucci und Taatgen, 2011](#)) argumentiert etwas differenzierter. Es geht auch davon aus, dass bei der Bearbeitung mehrerer Aufgaben oft zwischen den Aufgaben gewechselt wird. Allerdings erlaubt es eine gleichzeitige Bearbeitung, wenn zwei Aufgaben unterschiedliche Ressourcen verwenden, so dass zum Beispiel motorische Aktionen für eine Aufgabe und Gedächtniszugriffe für eine andere Aufgabe durchgeführt werden können.

[Kahneman \(1973\)](#) sieht die Aufmerksamkeit selbst als eine begrenzte Ressource bzw. als eine Kapazität, die dem Menschen in einem gewissen Maß zur Verfügung

steht. In seinem Kapazitätsmodell drückt Kahneman die Verteilung der Aufmerksamkeit auf motorische oder mentale Aktionen dadurch aus, dass zum Durchführen einer Aktion soviel Kapazität vorhanden sein muss, wie die Aktion an Aufwand erzeugt. Für ihn stehen also Aufwand und Aufmerksamkeit in einem engen Verhältnis. Sofern genug Kapazität vorhanden ist, lässt sich die Aufmerksamkeit daher auf unterschiedliche Aufgaben aufteilen.

Von der Sichtweise, dass uns Menschen nur begrenzte kognitive Ressourcen zur Verfügung stehen, die auf die zu bearbeitenden Aufgaben verteilt werden müssen, geht auch die **Multiple Resource Theory (MRT)** aus (Wickens, 2002). Wickens sieht die **MRT** jedoch nicht als ein Modell der Aufmerksamkeit, auch wenn sie stark mit diesem Begriff assoziiert ist. Die **MRT** identifiziert vier Dimensionen, anhand derer kognitive Ressourcen kategorisiert werden können. Wie bei der Threaded Cognition Theorie können auch nach der **MRT** zwei Aufgaben tatsächlich parallel bearbeitet werden, wenn die Anforderungen, die die Aufgaben an die Ressourcen stellen, sich in keiner dieser Dimensionen überschneiden. Wickens unterscheidet folgende Dimensionen (Wickens, 2002):

Verarbeitungsphase. In Modellen der Kognition werden typischerweise drei Phasen unterschieden: Informationsaufnahme, Informationsverarbeitung und das Antworten auf wahrgenommene Information. In der **MRT** werden Informationsaufnahme und Informationsverarbeitung zusammengefasst als eine Phase betrachtet.

Wahrnehmungsmodalität. Die **MRT** unterscheidet zwischen visueller und akustischer Wahrnehmung. Im Prinzip lassen sich aber auch weitere Modalitäten, wie zum Beispiel haptische Wahrnehmungskanäle berücksichtigen (Sarter, 2007).

Visueller Kanal. Innerhalb der visuellen Wahrnehmung wird zudem unterschieden zwischen dem **fokalen** und dem **ambienten Wahrnehmungskanal**. Die fokale Wahrnehmung ist zuständig für die Identifizierung von Objekten und das Erkennen von Detailinformationen, während über den ambienten Wahrnehmungskanal die Wahrnehmung der eigenen Position und Bewegung im Raum bewerkstelligt wird.

Kodierung der Antwort. Die Kodierung der Antwort, kann räumlicher Natur sein (typischerweise motorische Aktionen) oder aber verbaler Natur (typischerweise über Sprache).

Der **MRT** zufolge können daher gleichzeitig akustische und visuelle Informationen wahrgenommen werden sowie motorische und verbale Antworten gegeben werden. Der Zusammenhang zwischen der **MRT** und der Aufmerksamkeit wird ersichtlich, wenn man betrachtet, was passiert, wenn zwei Aufgaben Ressourcen der gleichen Kategorie belegen wollen, und beispielsweise die **fokale Wahrnehmung** beanspruchen. Es muss nun ausgewählt werden, welche Aufgabe die Ressource erhält. Dies bestimmt, auf welche Aufgabe die Aufmerksamkeit gerichtet ist. Beim Beispiel der fokalen Wahrnehmung lässt sich das auch formulieren als die Ausrichtung der *visuellen* Aufmerksamkeit. Werden von zwei Aufgaben unterschiedliche Ressourcen angefragt, so können beide aktiv bearbeitet werden. Die **MRT** favorisiert daher die Sicht, dass die Aufmerksamkeit in günstigen Situationen tatsächlich auf mehrere Aufgaben aufgeteilt werden kann.

Um nun ein ausführbares Modell der Aufmerksamkeitssteuerung zu erstellen, muss der Aufmerksamkeitsbegriff klar definiert und formalisiert werden. In dieser Arbeit wird hierzu eine sehr einfache und zum Teil auch eingeschränkte Definition der Aufmerksamkeit verwendet.

Definition 3 (*Aufmerksamkeit*)

Der Begriff Aufmerksamkeit beschreibt in den folgenden Texten die Aufgabe, die zur Zeit mental verarbeitet wird. Sie ist immer gerichtet auf genau eine Aufgabe bzw. ein Aufgabenziel. Wenn von Aufmerksamkeitssteilung gesprochen wird, so ist ein alternierender Wechsel der Aufmerksamkeit auf mehrere Ziele in kurzen Zeitscheiben gemeint.

Wie auch bei der Eye-Mind-Assumption von [Just und Carpenter \(1980\)](#) wird hier davon ausgegangen, dass der Blick immer auf Informationsquellen gerichtet wird, die für die Aufgabe, auf die die Aufmerksamkeit gerichtet ist, von Bedeutung sind. Bei dieser Sichtweise ist der Zusammenhang zwischen [visueller](#) und [mentaler Aufmerksamkeit](#) sehr eng und beinahe synonym. Hierauf wird in [Kapitel 3](#) näher eingegangen. Das dort beschriebene Modell der Aufmerksamkeitssteuerung kontrolliert die mentale Aufmerksamkeit und damit auch implizit die visuelle. Die spätere Evaluierung wird anhand von Eyetrackerdaten durchgeführt, aus denen Maße für die visuelle Aufmerksamkeit gebildet werden. Auch diesem Vorgehen liegt wiederum die Annahme zugrunde, dass ein sehr enger Zusammenhang zwischen visueller und mentaler Aufmerksamkeit besteht.

2.1.4 Modelle der Aufmerksamkeitsverteilung

Das AIE-Modell simuliert die menschliche Aufmerksamkeitsverteilung. In der Literatur finden sich bereits eine ganze Reihe an verschiedenen Modellen zur Aufmerksamkeitsverteilung. Hier sollen nun einige vorgestellt werden, um einerseits eine Einordnung des AIE-Modells in die bestehende Modelllandschaft geben zu können. Andererseits bilden einige Modelle die Grundlage des AIE-Modells und sind daher wichtig für die weitere Argumentation des AIE-Modells und für das Verständnis, welche Aspekte des AIE-Modells über den aktuellen Stand der Forschung hinausgehen.

Modelle der menschlichen Aufmerksamkeitsverteilung lassen sich in verschiedene Klassen einteilen. Eine für die Arbeit wichtige Unterteilung differenziert nach den Einflussfaktoren, die im Modell berücksichtigt werden. Man unterscheidet zwischen Bottom-Up- und Top-Down-Faktoren ([Wickens und McCarley, 2008](#)), bzw. exogenen und endogenen Faktoren ([Theeuwes, 1991](#)).

Die Top-Down-Faktoren werden auch als wissensgetriebene Faktoren bezeichnet ([Wickens und McCarley, 2008](#)). Dieses Wissen bezieht sich dabei auf die zu bearbeitende Aufgabe und die Eigenschaften der Umgebung. Es kann explizit über Instruktionen gelernt worden sein. Beim Autofahren stammen diese Instruktionen typischerweise aus der Fahrschule. So soll der Fahrer vor dem Rechtsabbiegen an einer T-Kreuzung sowohl nach links als auch nach rechts schauen. Es kann sich aber auch um aus Erfahrung gelerntes Wissen über statistische Abhängigkeiten in der Umgebung handeln, wie der Tatsache, dass beim Rechtsabbiegen der Blick nach links meistens mehr relevante Informationen bereithält, als der Blick nach rechts, da die von rechts kommenden Fahrzeuge das Abbiegen nicht behindern, sondern nur die von links kommenden ([Räsänen und Summala, 1998](#); [Werneke und Vollrath, 2013](#)).

Bei den Bottom-Up-Faktoren handelt es sich um Eigenschaften der Umgebung. Sie haben häufig keinen klaren Bezug zur aktuellen Aufgabe und beeinflussen die Aufmerksamkeit meist unbewusst. Diese Faktoren spielen vor allem dann eine Rolle, wenn wenig Wissen über eine Aufgabe vorhanden ist, oder gar keine klare Aufgabe verfolgt wird. Ein solches Verhalten lässt sich typischerweise beim zwanglosen Betrachten einer Szenerie oder eines Gemäldes beobachten, bei dem die visuelle Aufmerksamkeit automatisch von Bereichen angezogen wird, die eine hohe visuelle Auffälligkeit (engl.: Saliency) besitzen (Parkhurst et al., 2002).

Auch im Bereich der visuellen Suche spielt die Auffälligkeit eine essentielle Rolle. Hierbei besteht das Ziel darin, eine bestimmte Information in der Szenerie zu finden, ohne genau zu wissen, wo sie sich befindet und ob sie sich überhaupt in der Szenerie befindet. Dies ist zum Beispiel der Fall beim Suchen von Personen in Menschenmengen oder der medizinischen Diagnose mithilfe von CT- oder Ultraschallbildern. Ein Modell, das eine ganze Reihe von Bottom-Up-Faktoren berücksichtigt, ist das Guided Search Modell von Wolfe (2007). Wie viele andere computergestützte Modelle der visuellen Suche (z. B. (Itti und Koch, 2001), (Parkhurst et al., 2002), (Mancas et al., 2007)) berechnet es die von Koch und Ullmann (1985) eingeführten Saliency Maps (auch: Attention Maps). Diese geben für jeden Bildpunkt oder Bildbereich des vom Beobachter wahrgenommenen Bildes einen numerischen Wert für die Auffälligkeit des Bereichs an. Der Blick des Modells wird immer auf auffällige Bereiche gelenkt.

Bei den beschriebenen Situationen folgt die mentale Aufmerksamkeit meistens der visuellen Aufmerksamkeit, da Informationen erst dann in den mentalen Fokus geraten, nachdem der Blick auf sie gefallen ist. Bei den Top-Down-Faktoren ist der Weg umgekehrt. Werden wichtige Informationen für eine Aufgabe benötigt, auf die zur Zeit die mentale Aufmerksamkeit gerichtet ist, so wird der Blick auf die Informationsquellen gerichtet, von denen erwartet wird, dass sie die gewünschten Informationen zur Verfügung stellen.

Diese Arbeit beschäftigt sich nicht mit der visuellen Suche. Bottom-Up-Faktoren werden im weiteren Verlauf nicht berücksichtigt. Das AIE-Modell soll in Situationen verwendet werden, in denen mehrere Informationsquellen gezielt und häufig visuell abgetastet werden müssen (engl.: Scanning). Scanning-Verhalten tritt auf, wenn der Mensch zur Bearbeitung seiner aktuellen Aufgabe(n) Informationen von verschiedenen Informationsquellen benötigt, deren Orte er kennt. Dies tritt häufig im Zusammenhang mit technischen Systemen auf. Zum Beispiel beim Überwachen des Verkehrs und des Fahrzeugzustands beim Auto- oder Schifffahren aber auch im Flugzeugcockpit und bei Kontroll- und Leitständen von Industrieanlagen. Die Bediener in solchen Systemen besitzen typischerweise viel Wissen und Erfahrung über das System, so dass vor allem die wissengetriebenen Top-Down-Faktoren eine Rolle spielen (Wickens et al., 2008).

Im Folgenden werden einige Scanningmodelle vorgestellt, die im Rahmen dieser Arbeit von Interesse sind. Eine Übersicht über weitere Modelle findet sich zum Beispiel bei Moray (1986) oder Miller et al. (2004).

2.1.4.1 Senders' visuelle Scanningmodelle

Eines der ersten Modelle der visuellen Aufmerksamkeitsverteilung wurde von Senders (1964) bereits 1964 vorgestellt und im Verlauf der nächsten Jahre durch weitere Modellvarianten ergänzt (Senders, 1983). Es beschreibt, wie Bediener industrieller Großanlagen ihre visuelle Aufmerksamkeit auf die Anzeigen verschiedener Messgrößen des Systems verteilen.




Abbildung 2.2 – Senders' Versuchsaufbau mit vier Anzeigeeinstrumenten (nach (Senders, 1983)).

In einer Serie von Experimenten, bei denen die Probanden eine Reihe von analogen Anzeigeeinstrumenten beobachteten (s. Abbildung 2.2), variierte Senders vor allem die **Bandbreite** der angezeigten Signale. Die Probanden sollten anzeigen, wenn einer der beobachteten Werte in einen kritischen Bereich kam ($> 45 \mu A$ oder $< -45 \mu A$). Dies stellte für die Probanden einen Alarm dar, bei dem eine Taste als Reaktion gedrückt werden sollte. Bei dem Experiment wurden die Blicke der Probanden mit einer Kamera aufgezeichnet. Senders zeigte, dass die Signalbandbreite stark mit der visuellen Aufmerksamkeitsverteilung korreliert (Senders, 1964). Aufgrund des einfachen Aufbaus wurde das Experimentdesign in vielen anderen Arbeiten aufgegriffen und für die jeweiligen Zwecke angepasst (z.B. Smallwood, 1967; Donk, 1994; Miller et al., 2004; Fleetwood, 2005). Zur Evaluierung des AIE-Modells wird in Kapitel 4 ebenfalls auf einige Experimentergebnisse von Senders zurückgegriffen. Basierend auf unterschiedlichen Annahmen, erstellte Senders mehrere Modelle zur Vorhersage der **Blickfrequenz** auf ein Instrument und verglich diese mit den Experimentergebnissen. Die Hypothesen zu seinen ersten Modellen entstammten der Signaltheorie. So nahm er für sein **Periodic Sampling Model (PSM)** basierend auf dem Nyquist-Theorem (Shannon, 1948, Theorem 13) an, dass ein idealer Operator versucht, eine Anzeige mit der doppelten Signalfrequenz zu betrachten, um das angezeigte Signal zu rekonstruieren. Auch seine Vorhersage zur Blickdauer kam aus der Signaltheorie und basiert auf Shannons Entropiemass (Shannon, 1948).

Die Fokussierung auf die Signalbandbreite als den ausschlaggebenden Einflussfaktor ist zugleich auch ein Kritikpunkt an Senders Modellen (Miller et al., 2004). Es lassen sich damit zwar in vielen Situationen gute Vorhersagen erzielen, dennoch lässt sich bezweifeln, ob die Signalbandbreiten ursächlich für die beobachtete Aufmerksamkeitsverteilung sind. So bezieht Senders die Bedeutung, die das Signal für die Aufgabe des Beobachters hat, nicht in sein Modell ein. Die für den Beobachter wichtige Information, die im beschriebenen Versuchsaufbau über das Signal transportiert wird, betrifft die Frage, ob der angezeigte Wert aktuell im Alarmbereich ist

oder bald kommen wird. Dies wird in Senders' Modell nicht berücksichtigt. Ein Verändern der Alarmbereiche hat keine Auswirkung auf die Modellvorhersagen. Eine Diskriminierung von Alarmrate und Signalbandbreite ist in seinen Experimenten nicht möglich, da diese zum Teil perfekt korrelierten.

Miller et al. (2004) und Miller und Fu (2007) wiederholten Senders' Versuche, reduzierten jedoch die Korrelation zwischen der Signalbandbreite und der Alarmrate. Ähnliche Experimente wurden bereits von Bohnen et al. (1996) durchgeführt. Auf diese Weise wird die Aussagekraft der Signalbandbreite (proximal cue) als Hinweis auf Alarme (distal information, goal-directed task criterion) manipuliert. Dies wird als Aussagekraft des Umgebungsreizes oder ökologische Validität bezeichnet (Brunswick, 1956). So konnten Miller et al. zeigen, dass der Zusammenhang zwischen der Signalbandbreite und der visuellen Aufmerksamkeit stark durch den Grad der Aussagekraft der Signalbandbreite zur Abschätzung der Alarmrate beeinflusst wird, d.h. wie gut die Signalbandbreite als Indikator für relevante Ereignisse (Alarme) dient. Die Bedeutung der Signalwerte für den Beobachter sollte daher in einem Aufmerksamkeitsmodell berücksichtigt werden. Es zeigt gut, dass bei der Betrachtung der visuellen Aufmerksamkeit, immer auch die Aufgabe zu berücksichtigen ist, für die der Beobachter die wahrgenommenen Informationen benötigt.

Es lässt sich also annehmen, dass nicht nur die Signalbandbreite, sondern viel eher die Häufigkeit der relevanten Ereignisse (Alarme) die Aufmerksamkeitsverteilung beeinflussen. Das ist kein Widerspruch zu Senders Ergebnissen, da in seinen Experimenten die beiden Faktoren sehr stark korrelierten.

In dieser Arbeit wird daher der Einfluss der relevanten Ereignisse auf die menschliche Aufmerksamkeitsverteilung untersucht und bei dem in Kapitel 3 beschriebenen AIE-Modell als Einflussfaktor verwendet.

2.1.4.2 Carbonells visuelles Scanningmodell

Carbonell (1966) griff Senders' Idee auf, dass die Blickfrequenz zu einer Informationsquelle von der Signalbandbreite der Informationsquelle abhängt und erweiterte diesen Ansatz um einige Aspekte. Er ging von einem vergleichbaren Anwendungsfall wie Senders aus, bei dem der Beobachter ein Pilot ist und eine Reihe analoger Anzeigeelemente betrachtet.

Eine Einschränkung von Senders' Modell besteht darin, dass nur Anzeigesignale betrachtet werden, die sich stabil um einen konstanten Mittelwert bewegen und auf die der Beobachter oder die Umgebung nicht einwirken. In der Realität ist das jedoch fast nie der Fall. Ein Signal, das sich in eine Richtung weg vom Zielbereich bewegt, in dem der Beobachter das Signal halten will, wird sich typischerweise nicht selber stabilisieren, sondern sich immer weiter vom Zielbereich entfernen. Zudem wird ein Beobachter, der bemerkt, dass ein Signal kritische Werte annimmt, in irgendeiner Weise korrigierend eingreifen und das Signal wieder in den Zielbereich führen. Das gilt zum Beispiel auch beim Autofahren. Das Fahrzeug wird sich mit der Zeit immer weiter von der Fahrbahnmitte entfernen, bis der Fahrer schließlich korrigierend eingreift und das Fahrzeug zurück in die Fahrbahnmitte lenkt. Die beschriebene Einschränkung wird von Carbonell aufgehoben.

Zudem geht Carbonell davon aus, dass der Wert des Signals bei der letzten Beobachtung einen Einfluss darauf hat, wann der Beobachter das nächste Mal wieder auf die Informationsquelle blickt. Ist der Beobachter sich sicher, dass das Signal einen unkritischen Wert hat, so ist die Wahrscheinlichkeit gering, dass er seinen Blick auf die entsprechende Informationsquelle lenkt. In Abhängigkeit von dem zuletzt wahrgenommenen Wert steigt mit voranschreitender Zeit jedoch die Unsi-

cherheit darüber, ob das Signal noch immer in einem sicheren Zustand ist. Damit steigt auch die Wahrscheinlichkeit, dass der Beobachter den Blick wieder auf die Informationsquelle richtet. Die Grundidee, dass wachsende Unsicherheit die Blickwahrscheinlichkeit erhöht, wird in Kapitel 3 auch vom AIE-Modell aufgegriffen.

Carbonell berücksichtigt zudem, dass die Informationen auf verschiedenen Anzeigen einen unterschiedlichen Wert für den Beobachter haben. Dies drückt er über eine Kostenfunktion aus, die die Kosten beschreibt, die es zur Folge hätte, wenn eine Information übersehen wird. Schließlich integriert Carbonell die genannten Aspekte in einem Queueing-Modell, das annimmt, dass der Beobachter versucht die Kosten zu minimieren. Bei diesem Ansatz werden die Informationsquellen nicht separat betrachtet, sondern es wird berücksichtigt, dass die Informationsquellen miteinander um die visuelle Aufmerksamkeit konkurrieren. In späteren Arbeiten griff auch Senders diese Idee auf (vgl. Senders, 1983).

Carbonells Kostenfunktion ist wie folgt definiert (Carbonell, 1966):

$$C(t) = \sum_{i=1}^M \frac{C_i P_i(t)}{1 - P_i(t)} \quad (2.2)$$

Dabei ist t die aktuelle Zeit; $C(t)$ beschreibt die Kosten, die auftreten wenn der Beobachter zum Zeitpunkt t kein Anzeigeelement betrachtet; M ist die Anzahl der Instrumente; C_i definiert die Kosten, die anfallen, wenn der Wert des Anzeigeelements i unbemerkt einen Schwellenwert L_i überschreitet (Alarm); $P_i(t)$ ist die Wahrscheinlichkeit, dass die Anzeige i den Grenzwert L_i zum Zeitpunkt t überschreitet. Bei diesem Modell tritt nun das Problem auf, dass der Modellierer die Kosten C_i für jedes Instrument bestimmen muss. Die Bestimmung kann dabei nicht generell geschehen, sondern ist anwendungsabhängig und erfordert daher Expertenwissen.

Carbonell nimmt nun an, dass es das Ziel des Beobachters ist, die Kosten zu minimieren, indem er ein Anzeigeelement betrachtet, bei dem die Kosten des Nicht-Betrachtens und die Wahrscheinlichkeit eines Alarms momentan hoch sind. Die Kosten, die für das Betrachten der Anzeige i anfallen, definiert Carbonell durch:

$$C'_i(t) = C(t) - C_i P_i(t) \quad (2.3)$$

Der Beobachter versucht also $C'_i(t)$ zu minimieren. Die Bestimmung der Wahrscheinlichkeiten P_i sollen dabei den Anzeigewert und die Zeit während des letzten Beobachtens der Anzeige i berücksichtigen:

$$P_i(t) = P[y_i(t) \geq L_i | y_i(t - \Delta_i(t)) = Y0_i(t)] \quad (2.4)$$

Dabei ist $y_i(t)$ der Wert der Anzeige i zum Zeitpunkt t ; $\Delta_i(t)$ ist die Zeitspanne seit dem letzten Betrachten der Anzeige i , und $Y0_i(t)$ ist der Wert der Anzeige i während der letzten Beobachtung.

Die Einbeziehung der Schwellenwerte L_i ist eine wichtige Erweiterung zu Senders' Modell, da hierdurch die Aufgabenkriterien, nach denen sich der Beobachter richtet, berücksichtigt werden. Es ist demzufolge nicht so wichtig, wie häufig und schnell sich die angezeigten Informationen in einem AOI ändern, sondern wie häufig durch das Überschreiten eines kritischen Schwellenwertes Ereignisse auftreten, die für den Beobachter relevant sind. Auch dieser Ansatz wird im AIE-Modell aufgegriffen.

Carbonell et al. (1968) validierten Carbonells Modell anhand experimenteller Daten aus Versuchen mit Piloten. Beim Vergleich der Vorhersagen mit Vorhersagen, die mit Senders ursprünglichen PSM-Modell gewonnen wurden, zeigte sich, dass Carbonells Modell bei allen untersuchten Aspekten bessere Vorhersagen lieferte.

2.1.4.3 Das SEEV-Modell

Wickens (Wickens und McCarley, 2008; Wickens et al., 2001) entwickelte ebenfalls ein Modell zur Vorhersage der Aufmerksamkeitsverteilung. Das SEEV-Modell beschreibt den Einfluss von vier Hauptfaktoren (Saliency, Effort, Expectancy, Value) auf die Aufmerksamkeitsverteilung, deren Abkürzungen das Akronym SEEV bilden. Das Zusammenspiel dieser Faktoren wird in Wickens et al. (2003b) beschrieben durch:

$$P(A) = a \cdot \text{Saliency} - b \cdot \text{Effort} + c \cdot \text{Expectancy} + d \cdot \text{Value} \quad (2.5)$$

Dabei stellt Saliency einen Wert für die Auffälligkeit der Information in einem AOI A dar. Effort beschreibt den Aufwand, der nötig ist, um die Informationen aus dem AOI wahrzunehmen. Unterschiedliche Quellen für den Aufwand wurden in der Literatur untersucht. Horrey et al. (2005) geben zusammenfassend als Quellen physikalische Bewegungen wie zum Beispiel das Bewegen der Augen und des Kopfes oder das Auswählen einer Informationsansicht in einem Softwaremenü sowie Kosten durch zusätzliche kognitive Belastungen an.

Expectancy stellt einen Wert für die Erwartung dar, dass im entsprechenden AOI neue und relevante Informationen vorhanden sind. Nach Wickens et al. (2001) kann Erwartung sowohl durch die Bandbreite als auch durch die Häufigkeit von Ereignissen oder durch weitere Hinweise aus der Umgebung entstehen. Miller und Fu (2007) zeigten, dass auch wiederkehrende Muster in einem Signal neben der Bandbreite zusätzlich Hinweise auf zu erwartende Informationen liefern können. Der Value-Faktor beschreibt den Wert, den die Information in einem AOI für eine bestimmte Aufgabe hat (vgl. Carbonells Kostenfunktion, Gleichung 2.2).

Wickens unterteilt die einzelnen Faktoren in generische und anwendungspezifische Komponenten. Die generischen Komponenten sind durch Kleinbuchstaben gekennzeichnet und geben die allgemeinen Stärken der Einflussfaktoren an, während die anwendungsspezifischen Komponenten durch die ausgeschriebenen Faktoren gekennzeichnet sind und die Stärke des jeweiligen Einflussfaktors in einer konkreten Situation beschreiben. In der praktischen Anwendung werden die generischen Komponenten jedoch wenig berücksichtigt. Sie werden lediglich auf 0 gesetzt, wenn einzelne Einflussfaktoren nicht berücksichtigt werden sollen (vgl. z. B. Horrey et al., 2005; Steelman-Allen und McCarley, 2010; Fleetwood, 2005).

Das Ergebnis $P(A)$ der Formel stellt ein Gewicht für das AOI A dar, mit dem die Wahrscheinlichkeit geschätzt wird, dass der Beobachter momentan den Blick auf A gerichtet hat. Hierzu wird $P(A)$ ins Verhältnis gesetzt zur Summe der Gewichte aller AOIs. Bei der Blickverteilungsanalyse wird jedoch meist ein längerer Zeitraum betrachtet. In dem Fall wird das ermittelte Verhältnis als Schätzwert für die prozentuale Blickverweildauer (PDT) zur Informationsquelle A interpretiert.

In der Literatur finden sich zwei Varianten der Formel, bei denen die Erwartungs- und Wertparameter multiplikativ (Horrey et al., 2006, 2005; Wickens et al., 2001, 2003a; Steelman-Allen, 2011; Fleetwood, 2005) bzw. additiv (Gore et al., 2009; Wickens und McCarley, 2008; Miller et al., 2004) verknüpft werden. Die Frage, welche Variante sinnvoller ist, ist weiterhin offen. In der ursprünglichen Modellvariante wurde eine multiplikative Verknüpfung verwendet (Wickens et al., 2001), da dies zu dem für den Beobachter optimalen Blickverhalten führen sollte. Nach Wickens et al. (2008) lassen sich jedoch Argumentationen für beide Varianten finden. In ihren Untersuchungen zum Blickverhalten von Flugzeugpiloten lieferte die additive Formulierung im Vergleich zur multiplikativen eine bessere Anpassung an die Versuchsdaten. Auch Byrne und Kirlik (2004) verglichen die Vorhersagekraft der additiven und multiplikativen Formulierung. Für ihre Anwendung (eine Variation

von Senders' Experiment, s. Abbildung 2.2) lieferte ebenfalls die additive Formulierung bessere Vorhersagen.

Auch Miller et al. (2004) argumentieren, dass die multiplikative Formulierung die optimale Blickverteilung beschreibt. Allerdings erzielten auch sie in ihren Untersuchungen bessere Ergebnisse mit der additiven Variante. Sie nehmen an, dass die Ursache bei ihrem Experiment im fehlenden Langzeittraining unter Laborbedingung liegt. Erwartung und Wert sind wissensgetriebene Faktoren, deren Bedeutung für eine Aufgabe mit Erfahrung gelernt werden muss. Sie stellen daher die Vermutung an, dass für die Modellierung von Experten in einer Aufgabe, die multiplikative Variante bessere Vorhersagen liefern könnte.

Autofahrer sind eine sehr heterogene Gruppe. Es ist daher fraglich, welches hier die optimale Variante ist. Da für viele Autofahrer das Fahren meist seit mehreren Jahren ein alltägliche Aufgabe ist, lässt sich vermuten, dass für diese Fahrer die multiplikative und damit optimale Variante gute Ergebnisse liefert. Hierauf wird später in Abschnitt 5.8 bei der Analyse des Fahrermodells näher eingegangen.

Das SEEV-Modell wurde bereits erfolgreich in einer Reihe von Studien angewandt (z.B. Horrey et al., 2005; Wickens et al., 2008). Der Erfolg und praktische Nutzen des Modells mag dabei u. a. von der im Vergleich zu Senders' und Carbonells Modellen sehr abstrakten, dafür aber auch sehr allgemein anwendbaren Definition herrühren. Diese erlaubt es, das SEEV-Modell mit wenig Aufwand in realitätsnahen Untersuchungen an alltäglichen Aufgaben einzusetzen. So wurde es zum Beispiel zur Vorhersage der Aufmerksamkeitsverteilung von Piloten und Autofahrern in Simulatorexperimenten genutzt (Wickens et al., 2008; Gore et al., 2009; Horrey et al., 2005, 2006).

Allgemeingültigkeit ist eine sehr erstrebenswerte Eigenschaft für ein Modell. Der praktische Nutzen eines Modells ergibt sich jedoch auch aus dem Aufwand der Modellanwendung und der Genauigkeit der Ergebnisse. Um das SEEV-Modell anzuwenden, müssen vor allem die Koeffizienten der verschiedenen Einflussfaktoren sinnvoll belegt werden. Wickens, Horrey et al. zeigten, dass sowohl bei Fahrsimulationen (Horrey et al., 2006), als auch bei Flugsimulationen (Wickens et al., 2003a) eine sehr einfache Heuristik ausreicht, um gute Korrelationen zwischen Modellvorhersagen und Experimentdaten zu erhalten. Diese Heuristik wird als **Lowest-Ordinal-Algorithmus** bezeichnet. Dabei werden den einzelnen Faktoren möglichst kleine Ordinalzahlen in der Ordnung ihrer Ausprägung zugewiesen. Dieser Ansatz ist einfach, dafür ist jedoch die Vorhersagegenauigkeit nur schwer abschätzbar. Insbesondere besteht kein funktionaler Zusammenhang zwischen messbaren Ausprägungen wie zum Beispiel der Signalbandbreite bzw. Alarmrate und des operationalisierten Einflussfaktors (Erwartung). Dieselbe Alarmrate in unterschiedlichen Szenarien wird zu unterschiedlichen Faktorausprägungen führen, je nachdem welchen Rang die Ausprägung in den jeweilig betrachteten Szenarien einnimmt.

Neben der zwar ungenauen, dafür aber sehr einfachen Operationalisierung der Einflussfaktoren trägt auch die sehr allgemein gefasste Beschreibung des SEEV-Modells zur hohen Anwendbarkeit bei. Es werden einerseits **Bottom-Up-Faktoren** (Saliency und Effort) berücksichtigt, die hauptsächlich einen Einfluss auf das Verhalten in unbekanntem Situationen oder bei der visuellen Suche haben. Andererseits werden auch **Top-Down-Faktoren** (Expectancy und Value) berücksichtigt, die wiederum meistens die ausschlaggebenden Faktoren in bekannten Situationen sind. Dadurch lässt sich ein breites Spektrum an Szenarien untersuchen.

Das in dieser Arbeit entwickelte Aufmerksamkeitsmodell adressiert lediglich die Top-Down-Faktoren, da eine optimale Blickverteilung sich lediglich auf diese Faktoren stützen sollte (Wickens et al., 2008). Zudem zeigten Horrey et al. (2005), dass

in Studien mit Autofahrern, die Fahrer ihre Aufmerksamkeitsverteilung hauptsächlich anhand dieser Faktoren ausrichten.

2.1.4.4 Spezialisierungen des SEEV-Modells

In der Literatur finden sich auch einige Spezialisierungen und Erweiterungen des SEEV-Modells. So wird zum Teil eine Formulierung des SEEV-Modells verwendet, die lediglich die Top-Down-Faktoren berücksichtigt (z.B. Wickens et al., 2003a, 2008; Horrey et al., 2006) und als Expected-Value-Modell bezeichnet wird (Wickens et al., 2003a). Es findet Anwendung, wenn Situationen untersucht werden, die für die betrachtete Personengruppe alltäglich sind. Über diese Situationen besitzen die Personen viel Erfahrung und explizites Wissen. Daher sind hier vor allem die wissensgetriebenen Faktoren ausschlaggebend für das Blickverhalten (Wickens et al., 2008; Horrey et al., 2005). Nur mit diesen ist es möglich, das Blickverhalten optimal an die Bedürfnisse der Aufgabe anzupassen (Moray, 1986). Wickens et al. (2003a) definieren beim Expected-Value-Modell das Aufmerksamkeitsgewicht für eine Informationsquelle A als:

$$P(A) = BW_A \cdot \sum_{g \in G} (R_{A,g} \cdot V_g) \quad (2.6)$$

Dabei bezeichnet BW_A die **Bandbreite** der Informationsquelle A und beschreibt damit die Erwartungsfaktoren. Die Wertfaktoren werden hier etwas differenzierter betrachtet. Es wird eine Relevanzmatrix R angegeben, deren Elemente $R_{A,g}$ angeben, wie relevant die Informationen in der Informationsquelle A für die Aufgabe g sind. Die Priorität einer Aufgabe g wird über V_g angegeben. Durch Summieren der $R_{A,g} \cdot V_g$ -Terme über alle Aufgaben G wird der Wert der Informationen in der Informationsquelle A bestimmt. In Kapitel 5 werden die Vorhersagen des Expected-Value-Modells für das Blickverhalten in einer Fahrsimulatorstudie verglichen mit den Vorhersagen, die mittels des AIE-Modells erzielt werden.

Das **Attention-Situation Awareness (A-SA)**-Modell ist eine Erweiterung des SEEV-Modells. Es integriert das SEEV-Modell in ein umfassenderes und dynamisches Modell des Situationsbewusstseins (McCarley et al., 2002; Wickens et al., 2005). Nach Endsley (1995) baut sich das Situationsbewusstsein auf drei Ebenen auf. Die erste Ebene betrifft die Wahrnehmung von **Ereignissen** in der Umgebung. Die zweite Ebene betrifft das Verständnis der wahrgenommenen Informationen und ihrer Relevanz für die aktuelle Aufgabe. Die dritte Ebene behandelt schließlich die Fähigkeit, Ereignisse in der Umgebung vorherzusagen. Im **A-SA**-Modell wird nun das SEEV-Modell als ein Modul genutzt, um die erste Ebene zu beschreiben. Ein weiteres Modul (Belief-Module) beschreibt die zweite und dritte Ebene. Über das SEEV-Modul werden Gewichte für wahrgenommene Ereignisse berechnet und an das Belief-Modul weitergereicht. Dieses berechnet auf der Basis dieser Gewichte einen numerischen Wert für das Situationsbewusstsein. Dieser Wert wird wiederum zurück an das SEEV-Modul gegeben und moduliert dort die Erwartungsparameter. Die Annahme dahinter ist, dass ein hohes Situationsbewusstsein die Vorhersage von Umgebungsereignissen verbessert (Level 3 Situationsbewusstsein). Dies erhöht die Erwartung für die vorhergesagten Ereignisse. Der Zweck des **A-SA**-Modells besteht darin, menschliche Fehler aufgrund eines reduzierten Situationsbewusstseins vorherzusagen. Hierzu wird das **A-SA**-Modell in dem zu untersuchenden Szenario simuliert. Die Interaktion mit der Umgebung ist dabei jedoch minimal. Als Eingabe erhält das Modell lediglich eine zeitlich geordnete Sequenz von Ereignissen. Die einzige Ausgabe, die es liefert, ist die auf Basis des Situationsbewusstseins geschätzte

Fehlerwahrscheinlichkeit. Eine weitere Interaktion mit der Umgebung findet nicht statt. Insbesondere wird die Bearbeitung der durchzuführenden Aufgabe nicht simuliert und dementsprechend werden auch keine Aktionssequenzen erzeugt.

Das N-SEEV-Modell (Steelmann-Allen und McCarley, 2010; Steelmann-Allen, 2011) präzisiert das SEEV-Modell, indem es den Einfluss der Faktoren detaillierter modelliert. Hierzu bedient es sich einer Reihe weiterer Modelle, die speziell den Einfluss einzelner Faktoren beschreiben, und integriert diese in das SEEV-Modell. Der Fokus liegt jedoch auf den Bottom-Up-Faktoren, insbesondere der Saliency, da das Modell vor allem das Bemerkten (engl.: *noticing*) unauffälliger Ereignisse in der Peripherie vorhersagen soll.

Auch das in der vorliegenden Arbeit entwickelte AIE-Modell baut auf dem SEEV-Modell auf. Es fokussiert dabei auf die Top-Down-Faktoren und erweitert das SEEV-Modell, indem die Operationalisierung des Erwartungsparameters detaillierter modelliert wird. Zudem soll das AIE-Modell selbst in eine kognitive Architektur integriert werden, um dynamische Simulationen zu erlauben, die weitere Aspekte der menschlichen Kognition und Feedback aus der Simulation berücksichtigen. Das N-SEEV-Modell von Steelmann-Allen und McCarley (2010) ist zwar auch ein Simulationsmodell, es berücksichtigt aber nur wenige Aspekte der zu bearbeitenden Aufgabe, insbesondere keine dynamische Interaktion mit der Umgebung. Ihr grundlegender Ansatz zur Überführung des SEEV-Modells in ein Simulationsmodell beruht auf der Verwendung von Luce's Auswahlaxiom (Luce, 1959), bei dem die Wahrscheinlichkeit der Blickzuwendung zu einer Informationsquelle A über eine Gewichtung der Informationsquelle w_A (attentional weight) in Relation zur Gewichtung aller Informationsquellen \aleph erfolgt:

$$P(\text{select } A) = w_A / \sum_{B \in \aleph} w_B \quad (2.7)$$

Die gewichtete, probabilistische Auswahl zwischen mehreren Informationsquellen ist ein einfaches und auch gängiges Vorgehen bei Simulationsmodellen zur menschlichen Aufmerksamkeitsverteilung (z.B. (Bundesen, 1990), (Gore et al., 2009), (Wickens et al., 2005)). Dem Prinzip folgt auch Senders (1983) zweites Modell, der Random Constraint Sampler, ohne es jedoch so explizit zu benennen. Dieser Ansatz wird mit einigen Änderungen auch in dieser Arbeit verfolgt und in Kapitel 3 näher beschrieben.

2.2 Kognitive Architekturen

In den vorherigen Abschnitten wurden verschiedene Modelle zur menschlichen Aufmerksamkeitsverteilung vorgestellt. Die Aufmerksamkeit stellt jedoch nur einen Teilaspekt der menschlichen Kognition dar. Viele weitere Aspekte tragen zum Verhalten eines Menschen bei, wie Gedächtnisprozesse, motorische Prozesse, Emotionen, Erfahrungen oder auch die Gemütslage (z.B. Stress, Nervosität, Müdigkeit). Kognitive Architekturen stellen einen Rahmen dar, in dem die verschiedenen Hypothesen zu Teilaspekten der menschlichen Kognition, die relativ unabhängig von den jeweiligen Aufgaben sind, in einem ganzheitlichen Bild zusammengefasst werden (Ritter und Young, 2001).

In der Psychologie existiert eine enorme Wissensbasis zu einzelnen Aspekten des menschlichen Verhaltens, die in zahlreichen Experimenten gewonnen wurden. Insbesondere in den letzten 40 Jahren sind verstärkt Anstrengungen unternommen worden, dieses Wissen in kognitiven Architekturen zusammenzufassen und zu strukturieren (Byrne, 2007; Langley et al., 2009). Die Bestrebungen dazu kommen sowohl

aus der Psychologie selbst, wurden aber auch aus anderen Bereichen wie der Künstlichen Intelligenz oder dem Human-Factors- und dem Ingenieurbereich beeinflusst. Die künstliche Intelligenz und die Psychologie befruchten sich dabei gegenseitig. Ein gutes Beispiel sind hier die Pionierarbeiten von Allen Newell und Herbert Simon, die 1975 für ihre Arbeiten zur künstlichen Intelligenz und der Psychologie der menschlichen Kognition den Turing Award der ACM verliehen bekamen. Sie fassten das kognitive System als ein symbolisches System auf und überführten ihre Ideen zum Problemlösen in ein Computerprogramm, dem Logical Theorist (Newell und Simon, 1956). Basierend auf diesen und späteren Arbeiten entwickelte Newell zusammen mit Laird und Rosenbloom schließlich Soar (Laird et al., 1987; Newell, 1990) als eine der ersten computergestützten kognitiven Architekturen.

Der Zugang des Ingenieurwesens kommt dagegen eher aus der Intention, das Wissen der Psychologie auch für Nicht-Experten anwendbar zu machen. Eines der bekanntesten Beispiele ist hier sicherlich das GOMS-Konzept (Goals, Operators, Methods and Selection Rules) von Card et al. (1983), das zur Analyse von Mensch-Maschine-Schnittstellen verwendet wird. Es ermöglicht mit einfachen Mitteln die Zeit vorherzusagen, die zum Bearbeiten einer Aufgabe benötigt wird. GOMS wurde in verschiedene Richtungen weiterentwickelt, so dass sich in der Literatur verschiedene Varianten finden. Die KLM-GOMS-Variante (Keystroke-Level-Modelling) findet zum Beispiel Verwendung in CogTool (John et al., 2004), einem Werkzeug zur Analyse von graphischen Nutzerschnittstellen.

GOMS stellt bereits eine sehr vereinfachte kognitive Architektur dar. Es adressiert einige zentrale Themen der menschlichen Kognition in einem integrierten Modell. Dies ist eines der Hauptmotive für kognitive Architekturen. Sie bieten einen Weg, um psychologische Erkenntnisse in einem integrierten Modell zusammenzufassen. Meist beinhalten sie eine ganze Reihe an Modellen, die jeweils einen Teilaspekt der Kognition beschreiben. Dies beinhaltet neben Modellen zu den rein mentalen Prozessen oft auch Modelle zu sensorischen und motorischen Prozessen. Die Beschreibung geschieht dabei in allgemeiner Weise ohne auf ein bestimmtes Szenario einzugehen, in dem die Architektur Verwendung finden soll (Byrne, 2007).

In einer kognitiven Architektur lassen sich kognitive Agenten für bestimmte Aufgabenstellungen, wie zum Beispiel dem Autofahren, instanziiieren. Hierzu wird Wissen darüber, wie die Aufgabe bewerkstelligt wird oder werden soll, in einer formalen Beschreibung von der Architektur eingelesen. Bei regelbasierten Architekturen wird dieses Wissen in Form von Produktionsregeln beschrieben (Taatgen und Anderson, 2008), die auch als Aufgabenprozedur bezeichnet werden. In Abbildung 2.3 sind die genannten Aspekte grafisch dargestellt.

Um zu simulieren, wie der Agent die Aufgabe bewältigt, nimmt die Architektur jeweils den aktuellen Zustand der Umgebung wahr. Im Falle eines kognitiven Autofahrermodells kann dies zum Beispiel den Abstand zu Hindernissen oder die Position des Fahrzeugs auf der Straße beinhalten. Die Aufgabenprozedur beschreibt, wie die wahrgenommenen Informationen verarbeitet werden, um die Aufgabenziele zu erreichen. Als Ausgabe übermittelt die Architektur Aktionen an die Umgebung. Im Falle des Autofahrermodells können dies z. B. Pedal- oder Lenkradbewegungen sein. Durch Simulation des kognitiven Agenten in Interaktion mit der realen oder simulierten Umgebung lässt sich das Verhalten von Menschen in dem betrachteten Szenario als Abfolge dieser Aktionen vorhersagen.

Die in einer kognitiven Architektur instanziierten kognitiven Agenten unterscheiden sich von Agenten aus der Robotik vor allem dadurch, dass die Informationsverarbeitung durch Bedingungen beschränkt ist, die sich aus den integrierten Modellen der Kognitionsprozesse ergeben (Taatgen und Anderson, 2008).

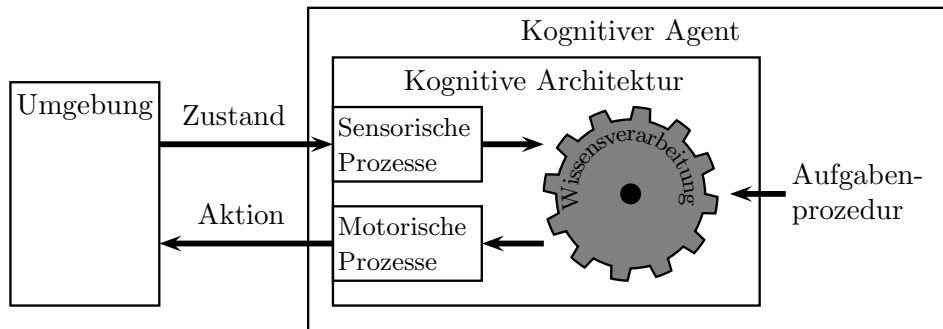


Abbildung 2.3 – Schematischer Aufbau eines typischen Systems zur Simulation eines kognitiven Agenten

Im Zusammenhang mit kognitiven Architekturen tritt der Begriff des Modells an vielen verschiedenen Stellen auf. Im weiteren Verlauf der Arbeit wird der Begriff Modell nach Möglichkeit mit einer differenzierenden Bezeichnung versehen.

- Das generelle Modell der Strukturen und Prozesse der menschlichen Kognition wird durch die kognitive Architektur dargestellt.
- Als kognitives Modell wird ein Modell zu einem bestimmten Aspekt der Kognition bezeichnet. Nach Möglichkeit wird jedoch eine genauere Bezeichnung wie Aufmerksamkeitsmodell oder Wahrnehmungsmodell verwendet.
- Die Beschreibung der zu untersuchenden Aufgabe wird im weiteren Verlauf als Aufgabenprozedur oder Aufgabenmodell bezeichnet.
- Die Kombination aus Aufgabenmodell und kognitiver Architektur wird als kognitiver Agent bezeichnet. Auch hier wird wenn möglich eine genauere Bezeichnung verwendet, die die Aufgabe des Agenten berücksichtigt, wie Fahrermodell oder Pilotenmodell.

2.2.1 Kognitive Agenten als Mittel zur Systemevaluation

Die Entwicklung und zunehmende Verfügbarkeit von Computern im 20. Jahrhundert eröffnete neue und potente Möglichkeiten zur Evaluierung großer, komplexer Systeme. Computer eignen sich sehr gut, um strukturiert ein formales Systemmodell zu erstellen und zu speichern. Vor allem aber lassen sich mithilfe von Computern die mit den formalisierten Systemen assoziierten Prozesse mittels verschiedenster Verfahren simulieren und analysieren (Engell et al., 2002). Die Simulation eröffnet dabei vielfältige Möglichkeiten:

- Simulationen können entscheidend zum Verständnis von Systemen beitragen, die für direkte, detaillierte Beobachtungen nicht oder nur schwer zugänglich sind. Hypothesen über die Struktur solcher Systeme können durch Simulation der Hypothese untersucht werden, wenn die Vorhersagen, die die Simulation liefert, überprüfbar sind (Klabbers, 2006).
- Komplexe Systeme, die manuell nur schwer zu analysieren sind oder bei denen physikalische Tests sehr kostspielig oder sicherheitskritisch sind, können automatisiert überprüft werden. Dies ist bei industriellen Entwicklungsprozessen ein alltägliches Vorgehen geworden. So werden neu entwickelte Gebäude,

Fahrzeuge oder andere Produkte bereits in der Designphase automatisch mit Computer Aided Design (CAD)-Werkzeugen auf Belastbarkeit und strukturelle Schwachstellen untersucht, indem grundlegende physikalische Wirkzusammenhänge simuliert werden (Maria, 1997).

- Schließlich lassen sich mit Computersimulationen auch Prognosen zu komplexen Prozessen erstellen, die mit viel Unsicherheit behaftet sind, wie die Finanzmarkt- und Klimaentwicklung (Crookall, 2013).

Insbesondere der erste Punkt stellt eine große Motivation in der Kognitionswissenschaft dar, aus dem sich einige kognitive Architekturen etabliert haben, in denen meist eine ganze Reihe an Hypothesen zu verschiedenen Aspekten der Kognition in ein Gesamtmodell integriert werden (Newell, 1990). Durch Simulation von Agenten in diesen Architekturen in verschiedenen Situationen und dem Vergleich zum Verhalten von Menschen in den gleichen Situationen lassen sich Rückschlüsse auf möglicherweise fehlerhafte Hypothesen ziehen.

Aber auch die anderen beiden Punkte spielen eine Rolle. Denn diese Architekturen lassen sich nicht nur zum rein psychologischen Erkenntnisgewinn nutzen, sondern auch um Arbeitsabläufe und die Interaktion mit technischen Systemen zu untersuchen und zu verbessern (Ritter et al., 2000). Aus Sicht der Systementwicklung ist dies eine konsequente Weiterführung der modellbasierten Entwicklung, indem nun auch der Nutzer als letzte Komponente des Gesamtsystems in die Simulation mit eingebunden wird.

Ein solches Vorgehen bietet einige Vorteile für die Systementwicklung, weist jedoch auch einige Probleme auf. Ein Vorteil ist, dass durch die Simulation des komplexen Systems Mensch die Möglichkeit besteht, den Kostenfaktor der menschlichen Versuchsperson bei Nutzerstudien zu reduzieren. Ein weiterer Vorteil besteht darin, dass die Beschreibung der Aufgabe des Nutzers in einer Aufgabenprozedur auf unterschiedlichen Abstraktionsniveaus durchgeführt werden kann. So lassen sich im Sinne des Digital Prototyping bereits einfache *Mock-ups* und frühe Prototypen eines neuen Systems untersuchen (John und Salvucci, 2005; Bellamy et al., 2011). Insbesondere lassen sich aber auch Langzeiteffekte prognostizieren, wie zum Beispiel Ausführungszeiten erfahrener Nutzer bei Routineaufgaben (Card et al., 1980) oder Fehlinteraktionen durch gelernte Sorglosigkeit (Lüdtke, 2005).

Problematisch ist jedoch oftmals die Erstellung des kognitiven Agenten. Hier spielen zwei potentiell kritische Unsicherheiten eine Rolle:

Validität der integrierten kognitiven Modelle. Es ist schwierig zu bestimmen, ob die Integration unterschiedlicher kognitiver Modelle in eine kognitive Architektur ein valides Gesamtmodell ergibt. Das Gesamtmodell ist häufig sehr komplex und unterscheidet sich von Architektur zu Architektur. Einige Architekturen bieten eine große Anzahl an freien Parametern, um ein großes Spektrum an Verhaltensweisen erzeugen zu können. Andere sind dagegen restriktiver und begrenzen stärker die möglichen Alternativen, mit denen kognitive Agenten modelliert werden können. (Taatgen und Anderson, 2008)

Formalisierung der Aufgabenprozedur. Auch das Wissen, das Menschen nutzen, um eine Aufgabe zu bearbeiten, ist nicht direkt beobachtbar. Die Herleitung der Aufgabenprozedur ist daher zum Teil sehr aufwendig. Je nach Zweck der Aufgabenprozedur existieren unterschiedliche Methoden, um diesen Prozess zu unterstützen (Diaper und Stanton, 2004). Für viele Aufgaben sind Menschen in der Lage, einen Teil ihres Wissens zu verbalisieren (Ericsson

und Simon, 1993). Die nötige manuelle Formalisierung in die Syntax der Prozedursprache einer kognitiven Architektur ist allerdings eine potentielle Fehlerquelle. Gravierender ist jedoch, dass die Verbalisierung durch die subjektive Eigenwahrnehmung selbst fehlerbehaftet ist und diese Fehler nur schwer zu entdecken sind (Russo et al., 1989). Gerade bei hochtrainiertem Verhalten sind Menschen oft nicht in der Lage ihr Wissen exakt zu verbalisieren. So können zum Beispiel Autofahrer meist beschreiben, wie sie Autofahren, aber nur bis zu einem gewissen Detaillevel. Wie der Zusammenhang zwischen wahrgenommenen Informationen und der gewählten Gaspedalstellung ist, können sie normalerweise nicht im Detail angeben.

So existieren für das Abstandhalten auch gleich eine ganze Reihe verschiedener Modelle, die versuchen das menschliche Verhalten zu erklären. Ossen und Hoogendoorn (2011) wählten fünf solcher Modelle und untersuchten, wie gut diese Modelle das Verhalten von Autofahrern im realen Verkehr beschreiben. Hier zeigt sich, dass Autofahrer verschiedene Strategien beim Autofahren anwenden. Das ist typischerweise auch bei anderen Aufgaben der Fall. Zum Teil wendet sogar dieselbe Person bei derselben Aufgabe unterschiedliche Strategien an. Newell (1973, S.299) bezeichnete dies als den glitschigen Aal der Psychologie. Es ist daher nicht immer sinnvoll eine einzelne repräsentative Aufgabenprozedur zu erstellen. Es kann einfacher und zuverlässiger sein, das Verhalten über mehrere potentielle Aufgabenprozeduren einzugrenzen und die Resultate der Modellierungsalternativen gegeneinander zu vergleichen (Kieras und Meyer, 2000).

Eng verbunden mit der Frage, wie Menschen eine Aufgabe bearbeiten, ist die Frage, welche Informationen sie dafür verwenden. Auch diese Frage können Menschen nicht immer im Detail für alle Aufgaben beantworten. Zum Teil sind sie sich nicht einmal darüber bewusst, wo sie kürzlich hingeschaut haben, um die benötigten Informationen wahrzunehmen (Tatler, 2001). Dennoch lassen sich objektive Zugänge zur Beschreibung des Blickverhaltens finden.

Eyetracker sind ein gutes Mittel, um zu bestimmen, welche Informationen über die fokale Wahrnehmung aufgenommen werden. Um zu identifizieren, welche Informationen aus der peripheren Wahrnehmung für Versuchspersonen relevant sind, lassen sich Verdeckungsexperimente durchführen, bei denen einzelne Informationen für die Versuchspersonen verdeckt werden. Aus der Leistung, mit der die Aufgabe bei fehlender Informationsquelle bearbeitet wird, werden Rückschlüsse auf die Relevanz der verdeckten Information gezogen. Auf diese Weise wurden zum Beispiel zwei Bereiche im visuellen Feld identifiziert, die für das Lenkverhalten beim Autofahren von großer Bedeutung sind (Land und Horwood, 1995; Hildreth et al., 2000). Auf diese Bereiche wird in Abschnitt 5.6 genauer eingegangen.

Eine weitere Möglichkeit besteht darin, über maschinelle Lernverfahren eine Reihe von Verhaltensmodellen zu erstellen, die mit unterschiedlichen Informationen trainiert werden. Die Vorhersagekraft der jeweiligen Modelle kann als empirischer Indikator für die Relevanz der verwendeten Informationen genommen werden. Ein solches Vorgehen wurde zur Erstellung eines dynamischen Fahrermodells von Eilers und Möbus (2011a) angewendet.

Diese Probleme behindern den Nutzen, den kognitive Agenten für die Evaluation der menschlichen Interaktion mit technischen Systemen bieten, jedoch nicht zwangsläufig. Ein wichtiges Ziel der Evaluation ist es, Schwachstellen aufzudecken.

Der Schritt der Modellgenerierung für den kognitiven Agenten stellt dabei bereits einen wichtigen Analyseschritt dar, da er eine detaillierte Beschreibung der Aufgaben des menschlichen Bedieners erfordert. Der Modellierer wird so gezwungen, Annahmen über die Interaktion der Nutzer mit dem System explizit zu formulieren.

Es werden im Folgenden einige bekannte kognitive Architekturen vorgestellt, die entweder eine besondere Relevanz für das AIE-Modell haben oder bereits genutzt wurden, um kognitive Fahrermodelle zu entwickeln. Dabei wird jeweils darauf eingegangen, wie Konzepte der visuellen Aufmerksamkeit in diesen Architekturen integriert sind bzw. welche Fahrermodelle in der jeweiligen Architektur umgesetzt wurden.

2.2.2 Die kognitive Architektur ACT–R

Eine der bekanntesten und in vielen Studien und Anwendungsgebieten evaluierten Architekturen ist ACT–R (Adaptive Control of Thought – Rational), die momentan bereits in der Version 6 vorliegt². Die ACT–R-Theorie wurde maßgeblich von John R. Anderson entwickelt (Anderson und Lebiere, 1998; Anderson, 2009).

2.2.2.1 Struktur

ACT–R baut auf zwei verschiedenen Wissensstrukturen auf, dem deklarativen und dem prozeduralen Wissen. Wissen wird in verschiedenen Modulen verarbeitet. Die Module repräsentieren dabei jeweils unterschiedliche kognitive Prozessmodelle, die miteinander interagieren. Die Architektur besteht aus acht Kernmodulen (s. Abbildung. 2.4). Diese sind das Declarative und Procedural Module, Motor, Speech, Vision und Auditory Module, sowie Goal und Imaginal Module (Bothell, 2012).

Das deklarative Wissen entspricht dem Faktenwissen, welches man über verschiedenen Dinge und deren Relationen untereinander besitzt. ACT–R organisiert das deklarative Wissen in Wissensseinheiten, sogenannten Chunks, die im Declarative Module abgespeichert werden.

Das prozedurale Wissen dagegen beschreibt, wie das deklarative Wissen genutzt wird, um eine Aufgabe auszuführen. Es stellt die Aufgabenprozedur dar und wird durch eine Menge von Produktionsregeln definiert, die im Procedural Module verarbeitet werden. Dieses Modul nimmt eine besondere Rolle ein. Es ist die zentrale Einheit für die Wissensverarbeitung. Dazu interagiert es mit jedem anderem Modul über Buffer, die jeweils einen Chunk enthalten können. Wie diese Chunks verwendet werden, ist in den Produktionsregeln definiert. Diese definieren Bedingungen an Chunks in den Modulbuffern. Das Procedural Module sucht nun nach Produktionsregeln, deren Bedingungen an die Chunks in den Buffern alle erfüllt sind. Aus diesen wählt es eine aus, die angewendet (gefeuert) wird. Beim Feuern werden Chunks in den Modulbuffern verändert. Wie diese verändert werden, ist in der Produktionsregel beschrieben.

Auf diese Weise werden Informationen an die Module übergeben, die diese dann parallel zum Procedural Module verarbeiten können. Dies kann zum Beispiel eine Aufforderung an das Motormodul sein, eine Taste zu drücken oder eine Aufforderung an das deklarative Gedächtnis, einen bestimmten Chunk zu suchen.

Die Module antworten, indem sie ihre Buffer ändern. Durch die Zustandsänderung wird wiederum dem Procedural Module mitgeteilt, dass es erneut nach passenden

²<http://ACT-R.psy.cmu.edu>

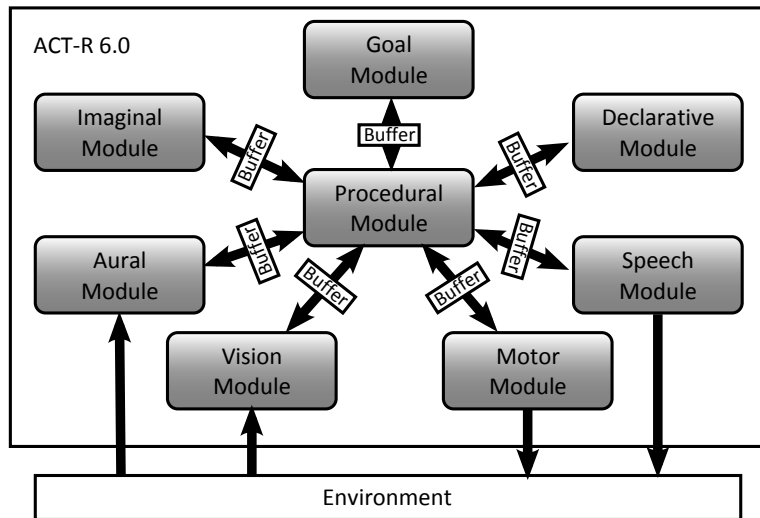


Abbildung 2.4 – Kommunikation zwischen ACT-R Modulen

Produktionsregeln suchen soll. Aus diesem iterativem Vorgehen entsteht schließlich die Aktionssequenz, die das Verhalten des kognitiven Agenten ausmacht.

2.2.2.2 Unterstützung durch fMRT-Daten

Die ACT-R Theorie wurde in den letzten 10-15 Jahren durch die Verfügbarkeit von Magnetresonanztomographen weiter unterstützt. Durch die funktionelle Magnetresonanztomographie (fMRT) werden Bereiche im Gehirn mit starker Stoffwechsellätigkeit identifiziert. Hierzu wird der Gehalt des durch die Stoffwechselfvorgänge oxygenierten Hämoglobins gemessen. Dies wird als **Blood Oxygenation Level Dependent (BOLD)**-Effekt bezeichnet.

ACT-Rs Kernmodule sind Gehirnregionen zugeordnet. Die Simulation eines ACT-R-Agenten und die damit verbundene Nutzung verschiedener Module generiert so eine Vorhersage zur Aktivierung der betreffenden Gehirnregionen. Die Korrelation zwischen den vorhergesagten und den in fMRT-Studien gemessenen BOLD-Effekten wird nun genutzt, um die theoretische Basis der Module zu untermauern (Anderson, 2007).

Zudem lässt sich auf diese Weise die Modellierung und Validierung von Aufgabenprozeduren unterstützen. Bestehen verschiedene Modellierungsmöglichkeiten für eine Aufgabe, so konnte bisher nur das äußerlich beobachtbare Verhalten von Probanden als Indikator dafür genutzt werden, welche Strategie der Proband verfolgt. Auch wenn bei der fMRT-Methode noch einige Probleme bewältigt werden müssen, so lassen sich doch prinzipiell Prozesse nachverfolgen, die sonst nicht direkt beobachtbar sind. Dieses Vorgehen kann genutzt werden, um eine Modellvariante zu untersuchen oder verschiedene Modellvarianten gegeneinander zu diskutieren (Anderson et al., 2008; Möbus et al., 2011b).

2.2.2.3 Blickverhalten von ACT-R-Agenten

Das Blickverhalten eines ACT-R-Agenten resultiert aus der Abfolge der gefeuerten Produktionsregeln. Diese können in ihren Aktionen definieren, auf welche Informationen der kognitive Agent seine visuelle Aufmerksamkeit richten soll. Um Blick-

bewegungen und die Wahrnehmung von Informationen zu simulieren, wurde das Vision Module in ACT-R integriert (Byrne und Anderson, 1998), das sich stark an der Implementierung des visuellen Prozessorsystems der kognitiven Architektur EPIC (Kieras und Meyer, 1997; Kieras, 2007) orientiert.

Um die visuelle Aufmerksamkeit auf eine Informationsquelle zu richten, wird durch eine Produktionsregel ein Visual Location Chunk im Visual Location Buffer des Vision Moduls abgelegt, der beschreibt auf welche Region der kognitive Agent seine visuelle Aufmerksamkeit richten soll. Das Vision Module kodiert die Informationen an diesem Ort in einem Chunk und stellt diesen im Visual Buffer zur Verfügung. Dieses Vorgehen führt dazu, dass der Fokus der visuellen Aufmerksamkeit immer auf Informationen liegt, mit denen sich der kognitive Agent auch mental beschäftigt. Teilweise nehmen Personen jedoch Informationen visuell wahr, die wichtig für eine Aufgabe sind, aber nicht im zentralen Blickfokus liegen. Dies zeigt sich zum Beispiel bei detaillierten Studien des textuellen Lesens (Reichle et al., 1998). In solchen Situationen trifft die Eye-Mind-Assumption nicht zu. Dies erschwert die Interpretation von Blickdaten und auch den Vergleich zwischen empirischen Blickdaten und den Daten eines kognitiven Agenten.

Um hier den Realitätsgrad zu erhöhen, entwickelte Salvucci (2001a), basierend auf bestehenden Modellen zu Blickbewegungen, das Eye Movements and Movement of Attention (EMMA)-Modell als eine ACT-R-Erweiterung. Es beschreibt u.a. das zeitliche Verhalten und die Präzision von Sakkaden sowie in begrenztem Umfang die Kodierungsdauer von Informationen. Zudem simuliert es, wie aufgabenrelevante Informationen wahrgenommen werden, ohne dass sie vom Blick fixiert werden. Allerdings basiert das EMMA-Modell auf einem Modell zum Lesen von Texten und ist speziell auf diese Situation angepasst.

Nyamsuren und Taatgen (2013) stellten konkurrierend zum EMMA-Modell mit dem Pre-Attentive and Attentive Vision (PAAV)-Modul eine allgemeine Erweiterung des Vision Moduls vor, bei der Bottom-Up-Prozesse der visuellen Wahrnehmung besser berücksichtigt werden. Sie validierten das PAAV-Modell anhand dreier visueller Suchaufgaben, da der Einfluss der Bottom-Up-Prozesse bei visuellen Suchaufgaben besonders hoch ist (Nyamsuren und Taatgen, 2013). Mit dem PAAV-Modell wird einerseits simuliert, welche Eigenschaften (Farbe, Form, Schattierung, Ausrichtung und Größe) eines Objektes im peripheren Sichtfeld wahrgenommen werden. Zum anderen wird simuliert, wie diese Eigenschaften die Blickbewegungen beeinflussen. Dazu wird ein Aktivierungslevel (VA) für jedes Objekt bestimmt, das sich ähnlich wie beim SEEV-Modell aus einem Top-Down-Anteil (TA) und einem Bottom-Up-Anteil (BA) zusammensetzt (Nyamsuren und Taatgen, 2013):

$$VA_i = W_{BA} \cdot BA_i + W_{TA} \cdot TA_i + N \quad (2.8)$$

Der Einfluss der beiden Anteile wird durch die Gewichte W_{BA} und W_{TA} angegeben. Zudem ist eine Rauschkomponente N enthalten, der eine logistische Verteilung zugrunde liegt. Der Top-Down-Anteil wird auf Basis des Chunks im Visual Location Buffer bestimmt, während der Bottom-Up-Anteil an ein Modell von Wolfe (2007) zur visuellen Suche angelehnt ist.

2.2.2.4 DistrACT-R

Ebenfalls von Salvucci entwickelt und im Rahmen dieser Arbeit von Interesse ist ein mit ACT-R modelliertes, kognitives Fahrermodell (Salvucci, 2006). Es beschäftigt sich vor allem mit der Frage der Lateralkontrolle (Lenkverhalten) und der Longitudinalkontrolle (Beschleunigungsverhalten) in Fahrsituationen. Von Haring

et al. (2012) wurde zudem ein Konzept zur Erweiterung des Fahrermodells vorgestellt, um auch Szenarien mit Kreuzungen und Überholmanövern zu behandeln. Das in Kapitel 5 beschriebene Fahrermodell baut auf dem gleichen Konzept der Lateralkontrolle auf. Das Fahrermodell von Salvucci verwendet hierzu einen diskreten Regler, der als Eingabe den Winkel der Fahrtrichtung zu zwei unterschiedlich weit entfernten Punkten auf der Straße verwendet (Salvucci und Gray, 2004). Die Lenkkorrektur wird mittels eines **Proportional-** und eines **Integralgliedes** für den Nahpunkt sowie eines Proportionalgliedes für den Fernpunkt bestimmt.

Dieses Fahrermodell nutzte Salvucci als Basis für sein DistrACT-R System (Salvucci, 2009), mit dessen Hilfe eine Abschätzung gegeben werden kann über die Auswirkungen, die eine Interaktion des Fahrers mit einer grafischen Nutzungsschnittstelle auf das Fahrverhalten hat. Der grundsätzliche Ansatz von DistrACT-R ist sehr ähnlich zu dem Vorgehen in dieser Arbeit. Durch Simulation eines kognitiven Fahrermodells in einem Fahrsimulator zusammen mit der Simulation des zu untersuchenden Systems sowie der Fahrer-System-Interaktion sollen Auswirkungen auf die Sicherheit des Fahrens ermittelt werden. Jedoch ist die Systeminteraktion bei DistrACT-R auf eine bestimmte Klasse von Systemen begrenzt.

Inspiziert vom CogTool-Ansatz (John et al., 2004, 2012) wird die Interaktionsbeschreibung mittels Modeling-by-Demonstration erstellt. Bei diesem Rapid Prototyping-Verfahren wird eine funktionslose Nutzerschnittstelle (User Interface (UI)) erstellt. Indem der Modellierer eine beispielhafte Interaktion mit der UI vornimmt, wird automatisch ein Modell der Interaktion erzeugt. Hierzu wird das ACT-Simple Framework verwendet, das aus einfachen Interaktionsoperatoren (z.B. Tastendrücken) automatisch eine vollständige ACT-R-Prozedur kompiliert (Salvucci und Lee, 2003). Im DistrACT-R-System wird dieses Interaktionsmodell in das Fahrermodell integriert und als Gesamtsystem simuliert.

Dieses Verfahren bietet den Vorteil, dass es sehr gut das Rapid Prototyping von Nutzerschnittstellen unterstützt, da die Erstellung des Interaktionsmodells sehr einfach ist und keine Erfahrung mit ACT-R erfordert, so dass viele Designalternativen in kurzer Zeit untersucht werden können. Jedoch werden bisher keine Systeme unterstützt, bei denen die Interaktion stark durch das Feedback des Systems beeinflusst wird. Hierfür müsste ein Prototyp der Systemsoftware vorliegen. Des weiteren werden nur einzelne Interaktionen berücksichtigt. Systeme, die kontinuierlich oder häufig wiederkehrend Interaktionen erfordern, wie z.B. Navigations- oder ACC-Systeme, werden nicht gesondert betrachtet.

2.2.3 Die kognitive Architektur Soar

Soar ist eine Architektur, die ursprünglich aus dem Bereich des Problemlösens stammt. Allen Newell entwickelte die erste Version in den frühen 1980er Jahren basierend auf den Ansätzen zum General Problem Solver (Newell und Simon, 1961). Heute liegt Soar bereits in der neunten Version vor (Lehman et al., 2006).

Wie auch ACT-R nutzt Soar zur Wissensverarbeitung Produktionsregeln. Die Arbeitsweise unterscheidet sich jedoch in einigen Aspekten (SoarTech, 2002). Während ACT-R-Regeln sequentiell auswählt und feuert, feuert Soar Produktionsregeln parallel. Die Regeln dienen hauptsächlich dazu, einen Operator auszuwählen. Dabei werden in immer neuen Schüben (RS_{p1} - RS_{p3} in Abbildung 2.5) solange alle ausführbaren Produktionsregeln gefeuert, bis ein passender Operator ausgewählt wurde. Daraufhin werden zur Anwendung des Operators wieder parallel eine Menge von Produktionsregeln gefeuert (RS_{a1} - RS_{a3} in Abbildung 2.5), die die für den Operator benötigten Aktionen durchführen. Vor der erneuten Operatorauswahl werden




Abbildung 2.5 – Soars Verarbeitungszyklus (nach (Laird, 2008)).

die Aktionen an die Umgebungssimulation weitergeleitet. Diese wiederum übermittelt ggf. Änderungen in der Umgebung an das Modell. Eine Produktionsregel stellt immer Bedingungen an den Zustand des Arbeitsgedächtnisses von Soar, welches als eine beschriftete Graphstruktur implementiert ist. Sind diese erfüllt, wird die Regel gefeuert und Änderungen am Arbeitsgedächtnis werden vorgenommen. Der beschriebene Ablauf ist schematisch in Abbildung 2.5 zu sehen. Man erkennt sehr gut, dass die sequentielle Natur der Wissensverarbeitung, anders als in ACT-R, nicht durch die Regelauswahl erzeugt wird, sondern durch die Operatorauswahl.

2.2.3.1 Blickverhalten von Soar-Agenten

Soar besaß ursprünglich kein detailliertes Modell zu sensorischen und motorischen Prozessen. Mit EPIC-Soar (Chong und Laird, 1997) gab es jedoch ähnlich wie in ACT-R Bestrebungen diese Prozesse detaillierter zu berücksichtigen. Während der letzten Jahre entwickelte zudem Wintermute (2009) ein Modell zur Verarbeitung räumlicher Informationen in Soar und Lathrop und Laird (2007) eines zur visuellen Informationsextraktion, die schließlich in die Erweiterung Soar/SVS (Spatial/Visual System) (Wintermute, 2010) mündeten, jedoch nicht Teil der offiziellen Soar-Version sind. Allerdings beschreibt SVS nur die Verarbeitung bereits wahrgenommener Informationen. Aspekte der Blickbewegungen werden nicht berücksichtigt.

2.2.3.2 Soar Fahrermodell

Aasmann (1995) entwickelte bereits 1995 ein kognitives Fahrermodell in Soar. Die Motivation bestand darin, die Eignung von Soar zur Modellierung von realen, komplexen Aufgaben wie dem Autofahren zu testen. Eine solche Fähigkeit forderte Newell (1990) von einer Unified Theory of Cognition, zu dessen Kandidaten er Soar zählte.

Aasmanns Fahrermodell nutzte zur Kontrolle der Aufmerksamkeit kein allgemeines Aufmerksamkeitsmodell. Stattdessen wurde die Kontrolle explizit für das betrachtete Szenario (Ampelanfahrt) mittels der Produktionsregeln von Soar modelliert.

2.2.4 Die kognitive Architektur MIDAS

Man-machine Integration Design and Analysis System (MIDAS) ist eine kognitive Architektur, deren Entwicklung von der NASA im Jahr 1985 mit dem Aircrew/Aircraft Integration (A³I) Programm begonnen wurde (Corker und Smith, 1993). Die bisherige Anwendungsdomäne liegt daher auch klar in der Modellierung von menschlichen Akteuren im Luft- und Raumfahrtbereich. Anders als ACT-R und Soar ist MIDAS nicht frei verfügbar, wurde aber bis heute ständig weiterentwickelt und liegt momentan in der fünften Version vor.

Intention von MIDAS ist es, den Designprozess von Cockpitsystemen virtuell zu unterstützen. Diese Schwerpunktsetzung wird schon deutlich bei der Begriffsdefinition von MIDAS. Anders als bei anderen kognitiven Architekturen umfasst der Name nicht nur die eigentliche Architektur, in der das Menschmodell ausgeführt wird, sondern auch sämtliche Werkzeuge zur Erstellung, Visualisierung und Analyse des Modells. Dies zeigt sich auch in den Ausgaben, die MIDAS produziert. Während bei ACT-R und Soar Wert darauf gelegt wird, dass die internen Abläufe während der Simulation nachvollziehbar sind, steht bei MIDAS eher die Bewertung dieser Abläufe im Vordergrund. So lieferte MIDAS bereits in der ersten Version Abschätzungen zu verschiedenen Ausführungsdauern und zur Arbeitsbelastung in den vier Dimensionen visuell, auditiv, kognitiv und motorisch (VACM) (Staveland, 1994). Die aktuelle Version unterscheidet dagegen sieben Kanäle: den visuellen, auditiven, räumlich kognitiven, verbal kognitiven, feinmotorischen, grobmotorischen und verbalen Kanal (Gore et al., 2011).

Zur Simulation der Entscheidungsprozesse der Cockpit-Crew nutzt MIDAS die APEX-Engine. APEX (Architecture for Procedure Execution) (Freed, 1998) ist wiederum eine eigenständige Architektur, die ebenfalls entworfen wurde, um den Systemdesignprozess in komplexen Umgebungen zu unterstützen.

Eine Besonderheit von MIDAS ist das anthropometrischen Menschmodell Jack³ (Blanchonette, 2010), das in MIDAS integriert ist und genutzt wird, um die motorische Interaktion mit dem Cockpit zu untersuchen. Es beinhaltet zudem ein einfaches, geometrisches Modell des fovealen, visuellen Blickfeldes.

2.2.4.1 Blickverhalten von MIDAS-Agenten

MIDAS ermöglicht es, das Blickverhalten auf zwei verschiedene Weisen zu modellieren. Wenn das Blickverhalten der menschlichen Akteure bekannt ist, kann es direkt über die Angabe von Fixationswahrscheinlichkeiten an die Aufgabenprozedur annotiert werden (Gore et al., 2009). Hierzu wird eine Tabelle erstellt, die für alle untersuchten Situationskontexte (z. B. verschiedene Flugphasen bei Pilotenmodellen) die Fixationswahrscheinlichkeiten für alle AOIs angibt. Blickbewegungen werden basierend auf diesen Wahrscheinlichkeiten probabilistisch erzeugt.

Um prädiktive Simulationen der Blickbewegungen zu ermöglichen, wurde in der aktuellen Version von MIDAS das SEEV-Modell integriert (Gore et al., 2009). Zur Operationalisierung der Einflussfaktoren verwendet MIDAS jedoch nicht den **Lowest-Ordinal-Algorithmus**. MIDAS ist mit Jack in der Lage, die Interaktion mit einem detailliertem Modell der Umgebung durchzuführen. Basierend auf diesem Modell werden die Effort-Faktoren dynamisch über die Größe der durchzuführenden Blickbewegung bestimmt. Alle anderen Faktoren werden statisch während der Modellierung definiert. Die Saliency-Faktoren lassen sich auf einer nach oben offenen Skala bestimmen. Allerdings wird die Auswahl dieser Faktoren durch einfache Faustregeln angeleitet, die Werte im Bereich von 0 bis 4 empfehlen. Für die Expectancy- und Value-Faktoren stehen die vier Ausprägungen *none*, *low*, *moderate* und *high* zur Auswahl, die den Werten 0, $\frac{1}{3}$, $\frac{2}{3}$ und 1 entsprechen.

Das AIE-Modell basiert ebenfalls auf dem SEEV-Modell und wird auf vergleichbare Weise in eine kognitive Architektur integriert. Dies wird in Kapitel 3 näher beschrieben. Allerdings findet beim AIE-Modell zum einen eine detailliertere Modellierung der Erwartung statt und zum anderen wird in MIDAS durch das SEEV-Modell die visuelle Aufmerksamkeit simuliert, während das AIE-Modell bei der mentalen Aufmerksamkeit ansetzt.

³Siemens PLM Solutions

2.3 Die kognitive Architektur CASCaS

Zur Evaluation des im nächsten Kapitel vorgestellten AIE-Modells wird dieses in die kognitive Architektur CASCaS (Cognitive Architecture for Safety Critical Task Simulation) integriert. Sie stellt somit eine für das weitere Verständnis wichtige Grundlage dar. Daher wird sie hier im Vergleich zu den anderen Architekturen ausführlicher vorgestellt.

Das Augenmerk von CASCaS liegt auf der einfachen und flexiblen Entwicklung von kognitiven Agenten in sicherheitskritischen Umgebungen. Dies sind in der Vergangenheit vor allem Pilotenmodelle (Frische et al., 2010; Lüdtke, 2005) und Fahrermodelle (Weber et al., 2009; Wortelen et al., 2011) gewesen. Die Entwicklung von CASCaS ist daher stärker anwendungsgetrieben als dies bei anderen Architekturen wie zum Beispiel ACT-R der Fall ist, deren Ziel es eher ist, eine einheitliche Theorie der menschlichen Kognition zu entwickeln.

Bei vielen Aspekten orientiert sich CASCaS allerdings an anderen kognitiven Architekturen wie Soar und ACT-R. Der Ansatz, dass Konzepte aus verwandten Architekturen übernommen werden und sogar Hybridarchitekturen gebildet werden, kann bei vielen Architekturen beobachtet werden (Taatgen und Anderson, 2010). Es lässt darauf hoffen, dass auf diese Weise eine sinnvolle Evolution kognitiver Architekturen entsteht, bei der sich bewährte Theorien herauskristallisieren und fehlerhafte durch bessere ersetzt werden. Ein solcher Entwicklungsprozess liegt der Entwicklung kognitiver Architekturen häufig zugrunde (Cooper, 2007).

Aufgrund der Ähnlichkeiten sollte die in Kapitel 3 vorgestellte Integration des AIE-Modells in CASCaS auch in anderen kognitiven Architekturen möglich sein. Auf die zentralen Voraussetzungen, die das AIE-Modell an eine kognitive Architektur stellt, wird ebenfalls in Kapitel 3 eingegangen. In den weiteren Abschnitten dieses Kapitels wird die Architektur und Arbeitsweise von CASCaS beschrieben. Dabei wird insbesondere auf die Aspekte der Informationswahrnehmung, Aufgabenstrukturierung und -ausführung sowie auf Multitasking eingegangen.

2.3.1 Grundstruktur

CASCaS entstand aus einer kognitiven Architektur, die ursprünglich von Lüdtke (2005) zur Simulation gelernter Sorglosigkeit entwickelt wurde. Gelernte Sorglosigkeit ist ein vereinfachender Lernprozess, der unter bestimmten Umständen dazu führen kann, dass kritische Sicherheitsüberprüfungen nicht durchgeführt werden. Die Grundstruktur der Architektur ist in weiten Teilen erhalten geblieben. Allerdings wurden die Komponenten kontinuierlich weiterentwickelt mit dem Fokus auf den relevanten Prozessen für die Modellierung von Autofahrern und Flugzeugpiloten (Lüdtke et al., 2009; Osterloh und Lüdtke, 2008; Lüdtke und Osterloh, 2009; Wortelen et al., 2011, 2013a).

Die Hauptkomponenten von CASCaS sind in Abbildung 2.6 dargestellt. Der typische Perzeptions-Kognitions-Aktions-Kreislauf, den viele kognitive Architekturen aufweisen, findet sich auch in CASCaS. Über ein Interface werden CASCaS Informationen aus der externen Umgebung zur Verfügung gestellt, die von der Wahrnehmungskomponente (Perception) gefiltert werden. Akustisch oder visuell wahrgenommene Informationen werden im Gedächtnis (Memory) abgelegt. Eine Wissensverarbeitungskomponente (Processing) kann diese Informationen nun nutzen, um ein bestimmtes Ziel zu erreichen. Dieses wird zusammen mit möglichen weiteren Zielen in der Zielkomponente (Goals) verwaltet. In der Wissensverarbeitung werden sowohl interne Zustände der Architektur wie Inhalte des Gedächtnisses oder

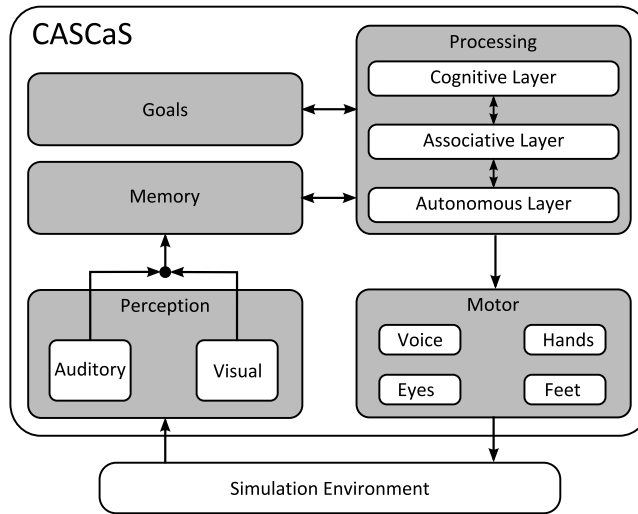


Abbildung 2.6 – Die Komponenten von CASCAS.

der Zielkomponente verändert, als auch Aktionen initiiert, die von der motorischen Komponente (Motor) ausgeführt und an die Umgebung übermittelt werden.

CASCAS lässt sich nur zusammen mit einer [Aufgabenprozedur](#) nutzen, die beschreibt, wie eine konkrete Aufgabe zu bearbeiten ist. Diese wird vor Beginn der Simulation von CASCAS geladen.

2.3.2 Konfiguration

Um einen kognitiven Agenten zu simulieren, wird eine [Agentenkonfigurationsdatei](#) eingeladen. Diese enthält im Wesentlichen vier Abschnitte zu folgenden Aspekten:

Aufgabenmodell. Die Komponente zur Wissensverarbeitung interpretiert das Aufgabenmodell eines kognitiven Agenten auf drei verschiedenen Ebenen. Je nach Ebene wird das Aufgabenmodell in unterschiedlicher Form definiert. Als Minimalanforderung erwartet CASCAS in diesem Abschnitt eine regelbasierte Prozedurdatei für die assoziative Ebene. Optional lässt sich zudem noch die kognitive Ebene laden sowie eine Reihe von Skills für die autonome Ebene (s. Abschnitt 2.3.6).

Parametrisierung. CASCAS enthält Implementierungen verschiedener kognitiver Prozesse, wie Lern- oder Aktivierungsprozesse im Gedächtnis, die sich in diesem Abschnitt aktivieren oder deaktivieren und zum Teil parametrisieren lassen.

Simulationsumgebung. CASCAS kann in Interaktion mit verschiedenen Umgebungssimulationen (z. B. Flug- oder Fahrsimulatoren) genutzt werden. Die Umgebung eines kognitiven Agenten kann dabei aus mehreren Komponenten bestehen. Typische Komponenten bei Fahrsimulationen sind zum Beispiel das Fahrzeug, umgebender Verkehr oder Assistenzsysteme. Für eine Simulation des Gesamtsystems muss der Datenaustausch definiert werden zwischen dem kognitiven Agenten und seiner Umgebung, mit der er interagiert. Dies beinhaltet zwei Aspekte:

Aus der technischen Sicht muss ein Kommunikationskanal aufgebaut und ein

Schedulingprozess definiert werden. Hierzu wird eine anwendungsspezifische Environment-DLL geladen, die diese Aufgaben übernimmt. CASCaS bietet einige allgemeine Implementierungen dieser DLL, um ein externes System über Netzwerk-Sockets oder eine High-Level Architecture (HLA)-Schnittstelle (Osterloh et al., 2012) anzubinden oder um eine abstrakte skriptbasierte Umgebung nutzen zu können. Auswahl und Konfiguration der Environment-DLL wird in diesem Abschnitt vorgenommen. Dies beeinflusst das Verhalten des kognitiven Agenten nicht.

Aus der Sicht des **kognitiven Agenten** muss zudem angegeben werden können, welche Informationen der Umgebung ihm zur Verfügung stehen und wie er diese beziehen kann. Ähnlich muss auch für die Aktionen des kognitiven Agenten definiert werden, welche Elemente in der Umgebung manipuliert werden können, wo diese sich befinden und wie sie manipuliert werden können. Hierzu wird eine Topologiedatei angegeben, die zum einen Bezeichner für die ausgetauschten Informationen definiert. Zum anderen findet eine Zuordnung von Informationen zu Bereichen in einer dreidimensionalen Beschreibung der Umgebung statt. Diese Topologie ermöglicht es der Motor- und der Wahrnehmungskomponente eine detailliertere Simulation von Wahrnehmungs- und motorischen Prozessen durchzuführen (s. Abschnitt 2.3.3)

Data-Logging und Debugging Schließlich lassen sich eine Reihe von Einstellungen vornehmen zur Datenaufzeichnung während der Simulation. Dies beinhaltet auch Debugging- und Visualisierungsoptionen.

Es wird nun eine Übersicht zu den einzelnen Komponenten und einigen Verarbeitungsmechanismen von CASCaS gegeben, soweit sie für das weitere Verständnis wichtig sind.

2.3.3 Perzeption und Motorik

Die Wahrnehmungs- und Motorkomponenten simulieren die Interaktionsprozesse mit der Umgebung. Zur Definition der Umgebung erwartet CASCaS als Eingabe eine Topologie-Datei, die alle relevanten Informationsquellen und Interaktionsmöglichkeiten der Umgebungssimulation in einem einheitlichen Format beschreibt.

Die Wahrnehmungskomponente simuliert Prozesse der akustischen und visuellen Wahrnehmung. Die Verarbeitung von visuellen und akustischen Signalen ist in vielen Aspekten sehr ähnlich (Shinn-Cunningham, 2008). So wie der visuelle Fokus auf ein Objekt gerichtet werden kann, kann auch der akustische Fokus ausgerichtet werden. Gespräche in lauten Menschenmengen sind hierfür ein Beispiel. Die akustische Aufmerksamkeit kann wie die visuelle Aufmerksamkeit bewusst (**Top-Down**) gesteuert sein, wenn man sich bewusst auf eine Geräuschquelle konzentriert oder aber automatisch (**Bottom-Up**) gesteuert, wenn zum Beispiel Warnsignale die Aufmerksamkeit auf sich ziehen. Ebenso wie Blicksakkaden eine gewisse Zeit benötigen, braucht auch ein Fokuswechsel der akustischen Aufmerksamkeit eine kleine Zeitspanne.

Trotz dieser Analogien zwischen visueller und akustischer Wahrnehmung ist das Modell der visuellen Wahrnehmung in CASCaS wesentlich detaillierter als das der akustischen Wahrnehmung. Der Grund hierfür liegt vor allem darin, dass in den meisten alltäglichen Situationen die visuelle Wahrnehmung eine sehr dominante Rolle spielt. Auch beim Autofahren wird der mit Abstand größte Teil der Informationen über die visuelle Wahrnehmung aufgenommen (Abendroth und Bruder, 2009,




Abbildung 2.7 – Topologie eines Pilotenmodells.

S.6), (MacAdam, 2003, S.105). Wichtige akustische Informationen beim Autofahren sind zudem häufig sehr auffällig (Hupen, Warntöne, Sirenen). Dies lenkt die Aufmerksamkeit des Fahrers automatisch auf das Geräusch, was typisch für einen Bottom-up-Prozess ist. Da das AIE-Modell jedoch auf die bewusst (Top-Down) initiierte Aufmerksamkeitsverteilung fokussiert, wird hier nur die visuelle Wahrnehmung beschrieben.

2.3.3.1 Umgebungstopologie

Die Dauer einer Blickbewegung ist von der Größe der Bewegung abhängig. Analog gilt dies für Handbewegungen zwischen verschiedenen Bedieninstrumenten. Für eine detaillierte Simulation dieser Bewegungen ist es daher notwendig, die Positionen der Informationsquellen und Bedieninstrumente in der Umgebung des kognitiven Agenten zu kennen.

Zu diesem Zweck kann für einen in CASCAS entwickelten Agenten eine 3D-Topologie der Umgebung erstellt werden (Osterloh et al., 2011). Hierbei lassen sich Form und Position sowohl von Informationsquellen (z. B. Displays) als auch von Bedieninstrumenten (z. B. Schalter und Controller) über eine XML-Struktur definieren. Mithilfe dieser Informationen kann die Motor-Komponente von CASCAS die Zeit berechnen, die ungefähr benötigt wird, um die Hand von einer Topologie-Komponente zu einer anderen zu bewegen. Das gleiche gilt auch für Blickbewegungen.

Die Informationsquellen in der Topologie werden annotiert mit Variablenamen und deren Typen. Über diese Annotation wird angegeben, welche Informationen in der Informationsquelle verfügbar sind. Die Zuordnung von Informationen zu Informationsquellen wird während der Simulation eines kognitiven Agenten genutzt, um die Blickbewegungen zu simulieren. Benötigt der Agent eine Information, so wird eine Blickbewegung zu einer Informationsquelle initiiert, die die Information bereitstellt.

Informationen, die der Agent wahrnimmt, werden über die Wahrnehmungskomponente in der Gedächtniskomponente abgelegt. Die Wissensverarbeitung kann auf diese Informationen im Gedächtnis zugreifen.

Über eine angeschlossene Rendering-Engine lassen sich die Umgebungstopologie sowie Kopf-, Blick- und Handbewegungen grafisch darstellen. In Abbildung 2.7 ist eine solche Darstellung für ein Pilotenmodell zu sehen, das im EU-Projekt HUMAN⁴ entwickelt wurde (Lüdtke et al., 2011).

2.3.3.2 Blickbewegungen

Die Blickbewegungen eines Agentenmodells in CASCaS werden in drei Phasen unterteilt. Dies sind die Reaktions-, Sakkaden- und Fixationsphasen, die jeweils eine gewissen Zeit benötigen (Osterloh und Lüdtke, 2008). Die hierbei simulierten Prozesse werden als Low-Level-Vision bezeichnet.

In der Reaktionsphase wird die Blickbewegung zum nächsten Fixationspunkt vorbereitet, während der Fokus im aktuellen Fixationspunkt bleibt. Die Dauer d_r dieser Phase wird über eine mittlere Dauer \bar{d}_r und eine Noise-Komponente $r_r \in [-\sigma_r, \sigma_r]$ definiert als $d_r = \bar{d}_r + r_r$. Als Defaultwerte für \bar{d}_r nutzt CASCaS basierend auf Fischer (1999) 170 ms und für σ_r 30 ms.

Die Sakkaden-Phase beschreibt die sakkadische Bewegung des Auges und gegebenenfalls die Bewegung des Kopfes. Basierend auf Arbeiten von Freedman (2001) wurde in CASCaS ein Modell zur Simulation von sakkadischen Blickbewegungen integriert (Osterloh und Lüdtke, 2008), das auf die Positionsinformationen der Topologie zurückgreift. Blickbewegungen setzen sich dabei aus Augen- und Kopfbewegungen zusammen. Die Größe einer Blickbewegung wird gemessen am Winkel, um den der Blick bewegt werden muss. Die Dauer der Blickbewegung wird schließlich in Abhängigkeit von ihrer Größe bestimmt. Ist für einen kognitiven Agenten keine Topologie spezifiziert, so wird die Sakkadendauer d_s wie bei der Reaktionsphase über eine mittlere Dauer \bar{d}_s und einer Noise-Komponente $r_s \in [-\sigma_s, \sigma_s]$ bestimmt: $d_s = \bar{d}_s + r_s$. Als Standardwerte der Parameter werden $\bar{d}_s = 120$ ms und $\sigma_s = 30$ ms verwendet.

Während der Fixationsphase wird die fokussierte Information wahrgenommen und im Arbeitsgedächtnis abgelegt. Die Dauer d_f dieser Phase ist analog zur Reaktionsphase über eine mittlere Dauer \bar{d}_f und einer Noise-Komponente $r_f \in [-\sigma_f, \sigma_f]$ definiert. Die Defaultwerte hier sind $\bar{d}_f = 200$ ms und $\sigma_f = 50$ ms.

Die Verweildauer einer einzelnen Fixation in einer Informationsquelle setzt sich somit aus Fixations- und Reaktionsphase zusammen und hat eine Länge von 370 ± 80 ms. Diese Berechnung stellt den von (Moray, 1986) angesprochenen **Datenakquisalgorithmus** zur Bestimmung der Fixationsdauer dar. Es ist ein einfaches Modell, das auf Durchschnittswerten basiert. In der Realität variieren die Fixationsdauern jedoch stark (Henderson und Hollingworth, 1998). Die durchschnittlichen Fixationsdauern werden z. B. durch Faktoren wie Helligkeit und Kontrast beeinflusst (Loftus et al., 1992) und unterscheiden sich in verschiedenen Szenarien (Rayner, 1998). Der hier verwendete Mittelwert entspricht etwa der Fixationsdauer, die bei der Betrachtung von statischen Szenerien (Fotografien) beobachtet wurde (Henderson und Hollingworth, 1998; Rayner, 1998).

Ein einzelner Blick zu einer Informationsquelle kann jedoch wesentlich länger dauern als hier angegeben, wenn er sich aus mehreren Fixationen oder Verfolgungsbewegungen innerhalb derselben Informationsquelle zusammensetzt. Eine Informa-

⁴www.human.aero




Abbildung 2.8 – Die drei in CASCAS implementierten Phasen der Low-Level Vision: Sakkaden-, Fixations- und Reaktionsphase, bei einer Blickbewegung von der Straße zum Tachometer und zurück.

tionsquelle kann wiederum unterteilt sein in kleinere Informationsquellen. Im Armaturenbrett eines Fahrzeugs finden sich beispielsweise eine Reihe an kleineren Informationsquellen, wie Geschwindigkeits-, Drehzahl-, Tank-, Ölstand- oder auch Navigationsanzeigen. Ist die Informationsquelle unterteilt in kleinere Informationsquellen, so simuliert CASCAS gegebenenfalls auch Sakkaden zwischen den einzelnen Quellen. Andernfalls werden längerer Blicke zur selben Informationsquelle wie eine Fixation behandelt.

Die beschriebenen Phasen der Low-Level-Vision sind in Abbildung 2.8 anhand eines Fahrermodells illustriert. In diesem Beispiel wird am Ende einer Fixationsphase zum Tachometer eine neue Blickbewegung zur Straße durch das Feuern einer Produktionsregel initiiert. Während der anschließenden Phase zur Vorbereitung der Sakkade verbleibt der visuelle Fokus auf dem Tachometer.

2.3.3.3 Handbewegungen

Ähnlich wie Augenbewegungen benötigen auch Handbewegungen eine gewisse Zeit. Bei diesen Bewegungen lässt sich differenzieren zwischen der Positionierungsbewegung, die nötig ist, um eine Hand von der aktuellen Position zum gewünschten Bedienelement zu bewegen und der Interaktionsbewegung, die nötig ist, um die gewünschte Interaktion mit dem Bedienelement durchzuführen.

Insgesamt berücksichtigt CASCAS bei Handbewegungen drei Phasen: Reaktions-, Positionierungs- und Interaktionsphase. Für die Reaktionsphase wird eine konstante Dauer von 50 ms verwendet. Die Positionierungsphase wird nur berücksichtigt, wenn die Hand bewegt werden muss. Ihre Dauer ist abhängig von der aktuellen Position der Hand und der Position des Bedienelements. Die Berechnung erfolgt basierend auf einer 3D-Erweiterung von Fitts's Law (Grossman und Balakrishnan, 2004). Die für die Berechnung benötigten Parameter, wie z. B. die Position und Größe des Instruments, werden der Topologie entnommen.

Die Dauer der Interaktionsphase hängt dagegen von der Art der Interaktion ab. CASCAS unterstützt häufig verwendete Interaktionsarten, wie zum Beispiel Greifen, Justieren und Tastatur- oder Mauseingaben.

Augen- und Handbewegungen sind häufig eng gekoppelt. Bei vielen Positionierungsbewegungen und einigen Interaktionsarten findet eine visuelle Kontrolle statt, um sicherzustellen, dass die Aktion korrekt durchgeführt wird. Dies lässt sich auch mit CASCAS simulieren, so dass bei Bedarf eine automatisch initiierte Augenbewegung stattfindet, die mit der Handbewegung koordiniert wird.

2.3.3.4 Sprache

Neben Augen- und Handbewegungen unterstützt die Motorkomponente von CAS-CaS rudimentär auch Sprachausgaben. Für diese Sprachausgaben lässt sich ein Textmuster angeben, auf dessen Basis die Sprechdauer berechnet wird. Zudem wird eine Semantik der gesprochenen Nachricht definiert und an die Simulationsumgebung weitergeleitet. Auf diese Weise lässt sich die Interaktion mehrerer kognitiver Agenten simulieren, die direkt miteinander kommunizieren.

2.3.4 Zielmodul

Aufgaben werden bearbeitet, um ein bestimmtes Ziel zu erreichen. In CASCaS werden die Ziele, die ein kognitiver Agent verfolgt im Zielmodul verwaltet. Die Organisation der Aufgabenziele folgt einer hierarchischen Struktur, so wie sie in GOMS-Modellen (Kieras, 2004) zu finden ist. Ein Agent kann zudem mehrere Ziele gleichzeitig verfolgen. Dies können vollständig unabhängige Ziele oder Subziele eines übergeordneten Ziels sein. Die Struktur und Arbeitsweise des Zielmoduls wird nun kurz erläutert.

2.3.4.1 Verarbeitungsmodi eines Ziels

Der Begriff Ziel wird typischerweise mit einem gewünschten Zustand verbunden, der erreicht werden soll. Die Aufgabenbeschreibung gibt an, wie das Ziel erreicht werden kann. Eine Aufgabenbeschreibung lässt sich in Unteraufgaben mit Teilzielen bis hin zu einzelnen Aktionen zerlegen. Durch sequentielles Abarbeiten aller Teilaufgaben wird schließlich das Gesamtziel erreicht.

Für einige Aufgaben kann sich die Situation jedoch auch etwas anders darstellen. Beim Autofahren lassen sich beispielsweise die Ziele identifizieren, das Fahrzeug in der Spur zu halten und einen Sicherheitsabstand zum Vordermann zu halten. Solche Aufgaben müssen fortwährend durchgeführt werden, damit sich das Fahrzeug stets in einem für den Fahrer akzeptablen Zustand befindet.

CASCaS unterscheidet daher zwei Verarbeitungsmodi. *Transiente* Ziele werden einmalig bearbeitet und sind mit einmaligem Erreichen des Ziels erledigt. *Persistente* Ziele werden immer wieder bearbeitet und werden erst als erledigt markiert, wenn die Simulation beendet ist oder eine Situation erreicht ist, die eine weitere Bearbeitung der Aufgabe nicht mehr erfordert.

Eine vergleichbare Differenzierung von Aufgaben wurde auch von Salvucci (2005) bei der Entwicklung eines ACT-R-Zielmoduls zur Simulation von Multitasking-Szenarien vorgenommen. Salvucci spricht jedoch nicht von transienten und persistenten Zielen, sondern von diskreten bzw. kontinuierlichen Aufgaben. Das Simple Simulation of Driver Performance (SSDRIVE)-Modell (Amantini und Cacciabue, 2009, S.247) verwendet dagegen die Bezeichnung reguläre bzw. permanente Aufgaben. Dabei werden die permanenten Aufgaben vor allem mit dem Skill-basierten Verhalten in Verbindung gebracht.

Unterschiede in der Verarbeitung von transienten und persistenten Zielen werden im nächsten Abschnitt aufgezeigt.

2.3.4.2 Verarbeitungszustände eines Ziels

Ein Ziel, das von einem kognitiven Agenten bearbeitet werden soll, kann unterschiedliche Zustände annehmen. Diese sind in Abbildung 2.9 dargestellt und werden im Folgenden beschrieben.

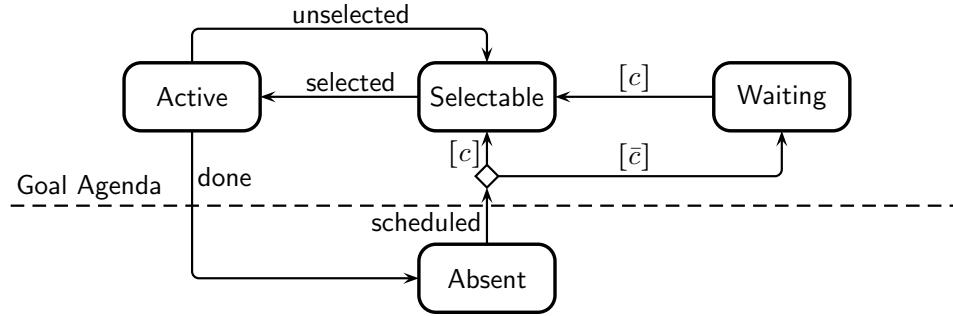


Abbildung 2.9 – Zustände und Zustandsübergänge eines Ziels. Ziele im Zustand *Waiting*, *Selectable* oder *Active* werden in der Zielagenda verwaltet.

Absent. Typischerweise werden in einer Aufgabenstruktur eine ganze Reihe an Zielen identifiziert, die jedoch nicht in jeder Situation und zu jedem Zeitpunkt relevant sind. Ziele, die zum aktuellen Simulationszeitpunkt nicht von Relevanz sind, werden zwar im Zielmodul verwaltet, haben jedoch keinen Einfluss auf das Verhalten eines kognitiven Agenten. Sie befinden sich im Zustand *Absent*. Soll ein Ziel ausgeführt werden, so verlässt es diesen Zustand und wird einer *Zielagenda* G hinzugefügt, die alle aktuell zu bearbeitenden Ziele beinhaltet. Auf der Zielagenda können sich Ziele in einem von drei Zuständen befinden.

Waiting. Werden zwei Ziele g und h in einer festen Reihenfolge ausgeführt, so dass h vor g bearbeitet werden muss, dann wird dies als eine Vorbedingung $c_{h,g}$ von g bezeichnet. Solange h Teil der Zielagenda ist, ist diese Bedingung nicht erfüllt:

$$c_{h,g} = \begin{cases} \text{true} & , \text{ wenn } h \notin G \\ \text{false} & , \text{ wenn } h \in G \end{cases} \quad (2.9)$$

Ein Ziel g kann eine Menge C_g von Vorgängerzielen haben, die alle vorab bearbeitet werden müssen. Erst wenn alle Vorbedingungen erfüllt sind ($\bigwedge_{h \in C_g} c_{h,g}$), kann auch g ausgeführt werden. Ein Ziel auf der Zielagenda, das durch eine Vorbedingung blockiert ist, befindet sich im Zustand *Waiting*.

Selectable. Sind alle Vorbedingungen eines Aufgabenziels erfüllt bzw. ist keine Vorbedingung vorhanden, so ist es prinzipiell bereit, bearbeitet zu werden. Ein solches Ziel befindet sich im Zustand *Selectable*.

Active. Auch wenn mehrere Ziele verfolgt werden, so ist die Aufmerksamkeit jedoch immer nur auf ein aktives Ziel gerichtet. Während der Simulation wählt das Zielmodul aus den auswählbaren Zielen eines aus, das ausgeführt wird. Dieses Ziel wechselt dann in den Zustand *Active*, in dem es durch Ausführen der entsprechenden Aufgabenprozedur bearbeitet wird. Ist das Ziel erreicht, so wird es von der Zielagenda entfernt. Wenn nicht anders angegeben, ist ein Ziel erreicht, sobald erfolgreich eine Produktionsregel für dieses Ziel ausgeführt wurde und sich kein Subziel mehr auf der Zielagenda befindet. Der Prozess der Regelauswahl und -ausführung wird in Abschnitt 2.3.6.1 näher beschrieben.

Persistente Ziele erreichen ihr Ziel nicht abschließend und werden daher nicht von der Zielagenda entfernt. Um die Ausführung anderer Ziele jedoch nicht zu

blockieren, können sie den Fokus an ein anderes Ziel abgeben und im Zustand *Selectable* auf der Zielagenda verbleiben. Sie stehen dann erneut zur Auswahl bereit. Wann ein Ziel den Fokus abgibt, muss vom Aufgabenmodellierer festgelegt werden. Dieses Vorgehen entspricht der von Salvucci (2005) vorgeschlagenen Iterating-Heuristik zur Behandlung von Multitasking-Situationen.

2.3.4.3 Zielauswahl

Bis auf den Übergang *Selectable* \rightarrow *Active* sind alle Zustandsübergänge determiniert. Bei der Wahl eines Ziels aus der Menge der auswählbaren Ziele stellt sich jedoch die Frage nach dem Auswahlalgorithmus. Dieser kann einen wesentlichen Einfluss auf das Verhalten des kognitiven Agenten haben, da er den Fokus der mentalen Aufmerksamkeit bestimmt.

In der bisherigen Implementierung verwendet CASCaS einen einfachen deterministischen Algorithmus. Dieser orientiert sich an einem in ACT-R implementierten Multitaskingmodell von Salvucci (2005). Hierbei ist die Zielagenda als eine verkettete Liste nach dem First In, First Out (FIFO)-Prinzip organisiert (s. Abbildung 2.10). Diese wird im Weiteren als Zielwarteschlange bezeichnet. Ein Ziel, das der Agenda hinzugefügt wird, wird an das Ende der Warteschlange eingereiht. Bei der Zielauswahl wird immer das erste Ziel aus der Warteschlange gewählt. Bei Erreichen des Ziels wird es aus der Zielwarteschlange entfernt. Wird es jedoch durch die Ausführung eines anderen Ziels unterbrochen (*Active* \rightarrow *Selectable*), so wird es erneut am Ende der Warteschlange eingereiht.

Ändert sich die Zielwarteschlange, so werden die Vorbedingungen der Ziele erneut überprüft. Ziele im Wartezustand, deren Vorbedingungen erfüllt sind, werden als auswählbar markiert. Existiert eine Vorbedingung $c_{h,g}$ und ist g in der Zielwarteschlange vor h eingeordnet, so wird g direkt hinter h verschoben. Auf diese Weise finden sich die Vorbedingungen auch in der Reihenfolge der Zielwarteschlange wieder. So wird keine Vorbedingung verletzt, wenn bei der Wahl des aktuellen Ziels immer das erste Ziel der Warteschlange gewählt wird.

Dies ist in Abbildung 2.10 beispielhaft an einer Zielwarteschlange mit den fünf Zielen A bis E illustriert. Die Vorbedingungen der Ziele B und E sind nicht erfüllt. Daher befinden diese sich im Zustand *Waiting*. Das Ziel A befindet sich am Anfang der Warteschlange und wurde daher ausgewählt. Die verbleibenden Ziele C und D haben keine Vorbedingungen und befinden sich daher im Zustand *Selectable*.




Abbildung 2.10 – Beispielhafte Zielwarteschlange mit fünf Zielen (A-E) und Vorbedingungen für die Ziele B und E. Das aktive Ziel ist grün markiert.

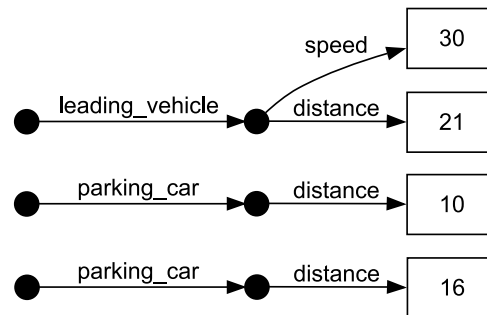


Abbildung 2.11 – Beispiel eines Auszugs des deklarativen Gedächtnisses, der ein Führungsfahrzeug mitsamt Geschwindigkeit und Abstand zu diesem beinhaltet, sowie zwei in unterschiedlicher Entfernung parkende Fahrzeuge.

2.3.5 Gedächtniskomponente

CASCAS unterscheidet zwei Arten von Wissen. Das ist zum einen das prozedurale Wissen, das beschreibt, wie Aufgaben bearbeitet werden, und zum anderen das deklarative Wissen, über das Fakten und Informationen beschrieben werden, die hilfreich für die Bearbeitung der Aufgabe sein können.

2.3.5.1 Struktur

Sowohl das prozedurale Wissen eines kognitiven Agenten als auch das deklarative Wissen werden in der Gedächtniskomponente innerhalb eines semantischen Netzes gespeichert. Das prozedurale Wissen ist in Form von Produktionsregeln im Gedächtnis enthalten, die jeweils mit einem Ziel assoziiert sind, das sie unterstützen. Die Verarbeitung der Produktionsregeln wird in Abschnitt 2.3.6 erläutert.

Das deklarative Gedächtnis ist ähnlich zum Arbeitsgedächtnis von Soar (Laird, 2008) als ein gerichteter Graph mit beschrifteten Kanten abgebildet. Ein Knoten im Graph wird als Gedächtniselement bezeichnet und eine Kante als Assoziation. Die Gedächtniselemente können numerische und symbolische Informationen enthalten. Die Bedeutung dieser Informationen ergibt sich aus den Assoziationen, die zu dem jeweiligen Gedächtniselement führen. In Abbildung 2.11 ist ein Beispielgraph zu sehen, der ein vorausfahrendes Fahrzeug sowie dessen Geschwindigkeit (in m/s) und den Abstand (in m) zu diesem Fahrzeug repräsentiert. Zudem enthält der Graph Informationen zur Entfernung zweier parkender Fahrzeuge.

Gedächtniselemente werden über eine **Punktnotation** referenziert, die der Attribut-Pfad-Notation in Soar ähnelt (Laird et al., 2012). So wird der Abstand zum vorausfahrenden Fahrzeug über den Pfad `leading_vehicle.distance` angegeben. Ein solcher Pfad wird als Gedächtnisdeskriptor bezeichnet. Die Struktur und der Inhalt des deklarativen Gedächtnisses kann durch zwei Komponenten verändert werden. Zum einen kann die Wissensverarbeitung auf das Gedächtnis zugreifen und es verändern (s. Abschnitt 2.3.6). Zum anderen werden wahrgenommene Informationen von der Wahrnehmungskomponente ins Gedächtnis geschrieben. In der Topologie-Datei wird dabei das Mapping der wahrgenommenen Informationen auf die entsprechenden Gedächtniselemente definiert. Wenn in der Topologiedatei die Informationsquelle `leading_vehicle` mit den Informationen `speed` und `distance` definiert ist, dann werden beim Betrachten der Informationsquelle die entsprechenden Gedächtniselemente `leading_vehicle.speed` und `leading_vehicle.distance` im Gedächtnis aktualisiert.

2.3.5.2 Verfügbarkeit von Gedächtniselementen

Wenn ein Gedächtniselement im Gedächtnis enthalten ist, bedeutet dies jedoch nicht immer, dass es auch für die Wissensverarbeitung verfügbar ist. Die Verfügbarkeit hängt stark vom Alter der gespeicherten Information ab. Insbesondere in dynamischen Situationen, in denen sich die Umgebung häufig ändert, spielt die Zeitdauer, seit der eine Information zuletzt wahrgenommen wurde, eine wichtige Rolle. Alte Informationen weichen häufig von der Wirklichkeit ab. Dies zeigt sich auch beim Autofahren. Die Lage des Fahrzeugs und der umgebende Verkehr ändern sich fortwährend, so dass der Fahrer Informationen zum Fahrzeugzustand und dem umgebenden Verkehr fortlaufend beobachten muss, um ein akzeptables Bild darüber zu erhalten. Aber auch in weniger dynamischen Situationen sind nicht alle Informationen verfügbar, da es mit fortlaufender Zeit immer schwieriger wird, sich an Informationen zu erinnern, je länger es her ist, dass diese zuletzt wahrgenommen oder verwendet wurden (Anderson et al., 1996).

Zudem lassen sich im Gedächtnis mehrere Teilgraphen mit identischer Kantenbeschriftung bilden. In einem solchen Fall ist die Referenzierung eines eindeutigen Pfades über die Punktnotation nicht mehr möglich. In Abbildung 2.11 ist dies zum Beispiel für die parkenden Fahrzeuge der Fall, da über den Deskriptor `parking.car` zwei Gedächtniselemente adressiert werden können. Um zu überprüfen, ob ein Element im Gedächtnis verfügbar ist bzw. welcher von mehreren möglichen Pfaden gewählt werden soll, kann einer von drei verschiedenen Algorithmen gewählt werden. Die Wahl des Algorithmus wird bei der Konfiguration eines kognitiven Agenten in der `Agentenkonfigurationsdatei` festgelegt.

Immer verfügbar. Dies ist die einfachste Variante, bei der ein Element immer dann verfügbar ist, wenn es im Gedächtnis enthalten ist. Lassen sich mehrere Elemente über den gleichen Gedächtnisdeskriptor ansprechen, wird immer das zuletzt veränderte Element ausgewählt.

Zielauswahl. Einem weiteren relativ einfachen Algorithmus liegt das generelle Aufgabenschema von Miller (1953) zugrunde. Demzufolge ist der erste Schritt bei der Bearbeitung einer Aufgabe typischerweise die Akquisition von Informationen, die zur erfolgreichen Bearbeitung der Aufgabe benötigt werden. Eine Gedächtniselement wird nun als verfügbar markiert, wenn es seit der Auswahl des aktuellen Ziels erzeugt oder verändert wurde. Dies hat zur Folge, dass nach der Auswahl eines neuen Ziels alle für das Ziel benötigten Informationen aktualisiert werden müssen, so dass der kognitive Agent zuerst den Blick auf die entsprechenden Informationsquellen richten muss. Auch bei diesem Algorithmus ist es so, dass wenn mehrere Elemente über den gleichen Gedächtnisdeskriptor ansprechbar sind, immer das zuletzt veränderte Element ausgewählt wird, sofern es nach der Auswahl des aktuellen Ziels verändert wurde.

Dieses Vorgehen bietet für viele Situationen eine einfache und ausreichende Abstraktion, um ein plausibles Verhalten des Agenten zu erzeugen. Dies ist insbesondere in Situationen der Fall, in denen sich die Informationen in der Umgebung ständig ändern. Um eine Aufgabe korrekt durchzuführen, sollte ein Agent typischerweise vorab sicherstellen, dass die hierfür relevanten Informationen aktuell sind. Autofahren ist ein Beispiel einer solchen Situation.

Aktivierung. Die dritte Alternative ist die komplexeste und ist vor allem dann sinnvoll, wenn Vergessensprozesse für das Verhalten des Agenten eine relevante Rolle spielen. Angelehnt an das ACT-R-Aktivierungskonzept werden

die Gedächtniselemente jeweils mit einem Aktivierungswert attribuiert. Die Berechnung des Aktivierungslevel richtet sich nach der Aktivierungsformel von [Anderson und Lebiere \(1998\)](#). Es wird für ein Gedächtniselement m zum Zeitpunkt t bestimmt über:

$$A(t, m) = \underbrace{\ln\left(\frac{n}{1-d}\right) - d \cdot \ln(t - t_0)}_{B(t, m)} + S(t, m) \quad (2.10)$$

Die Aktivierung setzt sich aus zwei Komponenten zusammen. Über die Baselevel-Aktivierung $B(t, m)$ wird berücksichtigt, wie häufig ein Gedächtniselement verwendet wurde, und wie lange die letzte Nutzung her ist. Dabei gibt n die Häufigkeit an und t_0 den Zeitpunkt der letzten Nutzung. Wenn ein Gedächtniselement erst kürzlich verwendet wurde oder aber sehr häufig, dann ist die Baselevel-Aktivierung sehr hoch. Seit der letzten Verwendung nimmt die Aktivierung kontinuierlich ab. Die Abnahmegeschwindigkeit wird über die Abklingrate d bestimmt. Anderson und Lebiere geben eine etwas andere Berechnung der Baselevel-Aktivierung an, die Arbeiten von [Anderson und Schooler \(1991\)](#) entstammt. Die hier dargestellte Formulierung entspricht der auf Rechenzeit optimierten Approximation, die standardmäßig auch in ACT-R verwendet wird ([ACT-R Tutorial Unit 5](#)).

Über die zweite Komponente der Aktivierungsformel ($S(t, m)$ - Spreading Activation) wird der aktuelle Kontext, in dem sich der kognitive Agent befindet, bei der Berechnung der Aktivierung berücksichtigt ([Lüdtke und Osterloh, 2010](#)). Die in CASCAS verwendete Berechnung weicht jedoch etwas von derjenigen in ACT-R ab. In ACT-R stellen die [Buffer](#) Quellen der Aktivierung für [Memory-Chunks](#) dar ([Bothell, 2012](#)). Die Aktivierung der Chunks im deklarativen Gedächtnismodul geschieht basierend auf Assoziationen, die zwischen Chunks in den Slots der Buffer und Chunks im Gedächtnismodul bestehen. In der Standardeinstellung wird jedoch nur der Goal-Buffer als Aktivierungsquelle verwendet ([ACT-R Tutorial Unit 5](#)).

In CASCAS stellen lediglich die Ziele Aktivierungsquellen dar. Die Verteilung von Aktivierung auf die deklarativen Gedächtniselemente geschieht basierend auf Assoziationen, die direkt zwischen den Zielen und den deklarativen Gedächtniselementen bestehen. In der Standardeinstellung von CASCAS ist dieser Spreading-Activation-Prozess jedoch deaktiviert.

2.3.6 Wissensverarbeitung

Die zentrale Komponente von CASCAS ist die Wissensverarbeitung. Hier wird die Aufgabenprozedur basierend auf den im Gedächtnis enthaltenen Informationen ausgeführt. Dabei kann Verhalten auf drei Ebenen erzeugt werden, die miteinander interagieren. Die Aufteilung der Ebenen richtet sich nach [Rasmussens \(1983\)](#) drei Performance-Ebenen. Eine ähnliche Unterteilung findet sich auch bei [Fitts und Posner \(1973\)](#) und [Anderson \(2000\)](#), die das Erlernen von Fertigkeiten in drei Phasen unterteilen. Für die Bezeichnung der drei Ebenen der Wissensverarbeitung verwendet CASCAS die Terminologie von [Fitts und Posner \(1973\)](#):

Kognitive Ebene. Auf der kognitiven Ebene wird wissensbasiertes Verhalten generiert. Diese Ebene wird vor allem in ungewohnten Situationen aktiv. In diesen Situationen ist das Verhalten einer Person vor allem durch das Ziel bestimmt, das sie verfolgt. Aus dem Wissen, das zu der Situation vorhanden

ist, werden Aktionen und Verhaltensweisen gefolgert, die sinnvoll erscheinen, um das Ziel zu erreichen. Für diese Arbeit wird die kognitive Ebene nicht weiter berücksichtigt, da sie Verhalten in ungewohnten Situationen repräsentiert. Das AIE-Modell ist jedoch zur Modellierung des Verhaltens erfahrener Personen gedacht. In den Anwendungsfällen dieser Arbeit ist die kognitive Ebene immer ungenutzt.

Assoziative Ebene. In bekannten Situationen zeigen Menschen meist ein regelbasiertes Verhalten. Dabei werden Produktionsregeln angewendet, die vorab zum Beispiel durch Instruktionen oder beim Lösen von Problemen auf der kognitiven Ebene erlernt wurden. Typischerweise zeichnet sich das regelbasierte Verhalten dadurch aus, dass es bewusst ausgeführt wird und von der jeweiligen Person artikuliert werden kann (Rasmussen, 1983). Der Zweck, den eine Produktionsregel verfolgt, ist immer das Erreichen eines Ziels. Um ein Ziel zu erreichen, muss häufig jedoch eine ganze Sequenz von Produktionsregeln ausgeführt werden. Dies wird als Prozedur bezeichnet.

Produktionsregeln können nicht beliebig schnell hintereinander gefeuert werden. Die minimale Dauer zwischen zwei Regeln hat bei vielen regelbasierten kognitiven Architekturen einen essentiellen Einfluss auf die Bearbeitungszeit. Für die Länge von Soars Entscheidungszyklen wurde ursprünglich eine minimale Dauer von 60 ms angegeben (Newell, 1990). Die Zykluszeit des MHP (Model Human Processor) (Card et al., 1983) betrug sogar 70 ms. In vielen Architekturen wie ACT-R (Anderson, 2009) und EPIC (Kieras, 2007) hat sich jedoch eine Dauer von 50 ms etabliert. Dies ist auch der Wert, den CASCaS verwendet (s. Abbildung 2.12).

Das AIE-Modell verwendet Produktionsregeln, um die Erwartung eines kognitiven Agenten zu operationalisieren. Im nächsten Abschnitt wird daher etwas genauer auf die Struktur und Semantik von CASCaS' Regelsprache eingegangen.

Autonome Ebene. Nach Rasmussen (1983) lassen sich hochgelernte Bewegungsabläufe (Skills) durchführen, ohne dass eine bewusste Kontrolle nötig ist. Sie werden vor allem durch sensorische Eindrücke und einer vorhandenen Absicht initiiert. Beim Autofahren besteht eine solche Absicht zum Beispiel darin, das Fahrzeug in der Spur zu halten, während eine unbewusste Steuerung der Lenkbewegungen stattfindet. Dennoch kann das Lenkverhalten bewusst situationsabhängig moduliert werden, um das Fahrverhalten zum Beispiel den Straßen- oder Wetterbedingungen anzupassen.

In CASCaS werden Skills auf der autonomen Ebene ausgeführt. Sie lassen sich durch spezielle Regelkommandos von der assoziativen Ebene aus starten und bei Bedarf kontrollieren (s. Abbildung 2.12). Über die Agentenkonfigurationsdatei werden sie beim Starten eines kognitiven Agenten dynamisch als Laufzeitbibliothek eingeladen. Ein Skill hat die Möglichkeit auf Gedächtnisinhalte zuzugreifen und motorische Aktionen auszuführen. Die Implementierung eines Skills unterliegt rein technisch keinen Restriktionen.

Prinzipiell ist es bedenklich, in kognitiven Architekturen die Möglichkeit anzubieten, beliebigen Programmcode auszuführen. Je mehr Zwänge eine Architektur dem Modellierer auferlegt, desto besser lassen sich Plausibilität und Grenzen der zugrunde liegenden Theorie prüfen (Taatgen und Anderson, 2008). Laird und Wray (2010) erstellten eine Liste mit Anforderungen an generelle kognitive Architekturen, die explizit das Verbot der Ausführung von beliebigen Programmcode enthält (Laird und Wray, 2010, Anforderung R0).

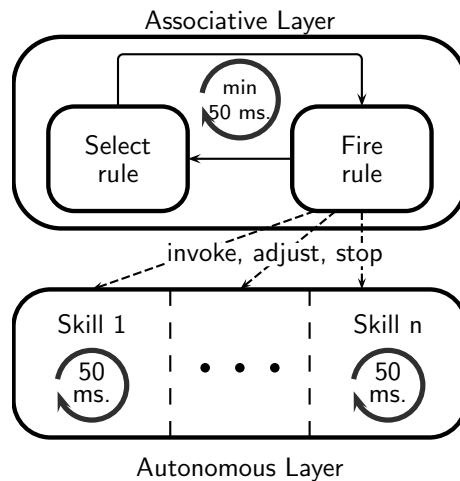


Abbildung 2.12 – Assoziative und autonome Ebene. Die Regelverarbeitung erfolgt sequentiell auf der assoziativen Ebene mit einer maximalen Feuerfrequenz von 50 ms, während auf der autonomen Ebene mehrere Skills parallel ausgeführt werden können.

Da das Verhalten auf der autonomen Ebene jedoch stark trainiert ist, sich nur gering durch weitere Lerneffekte verändert und vor allem durch äußere Stimuli getrieben wird, lässt es sich durch einfache Input-Output-Relationen beschreiben. Durch das flexible Konzept der Laufzeitbibliotheken lassen sich mit CASCAS verschiedene Modellierungsansätze für diese Beschreibung testen. So wurden beispielsweise für das Lenk- und Beschleunigungsverhalten von Fahrermodellen sowohl kontrolltheoretische Modelle (s. Abschnitt 5.6) als auch probabilistische Ansätze (Eilers und Möbus, 2011b) integriert.

Ein wichtiger Unterschied bei der Ausführung von Skills im Vergleich zur assoziativen Ebene besteht darin, dass mehrere Skills parallel ablaufen können, während die Verarbeitung auf der assoziativen Ebene sequentiell ist (s. Abbildung 2.12). Die klare Trennung der Ebenen, wie sie bei CASCAS zu sehen ist, stellt allerdings nur eine Abstraktion da. Eine klare Zuordnung, auf welcher Ebene ein bestimmtes Verhalten anzusiedeln ist, ist in der Realität schwierig zu treffen, da dies unter anderem von der individuellen Erfahrung abhängt. Wichtiges Unterscheidungsmerkmal ist jedoch, dass Verhalten auf der autonomen Ebene unbewusst abläuft und häufig nicht im Detail artikuliert werden kann (Rasmussen, 1983).

2.3.6.1 Prozedursprache

Die Aufgabenprozedur auf der assoziativen Ebene ist Kernstück der Wissensverarbeitung von CASCAS und muss für jeden kognitiven Agenten angegeben werden. Um die Prozedur für einen Agenten zu laden, wird in der [Agentenkonfigurationsdatei](#) der Name einer Prozedurdatei angegeben, die als Aufgabenbeschreibung eine Menge von Produktionsregeln beinhaltet sowie einige Initialisierungsanweisungen. Zur Illustration der Regelsyntax ist in Prozedurabschnitt 2.1 eine Beispielproduktionsregel dargestellt, die Teil der Prozedur des Agenten ist, der in Kapitel 4 vorgestellt wird. Die dort abgebildete Produktionsregel aktiviert die vier Unterziele `observe_gauge_1` bis `observe_gauge_4`, wenn auf einem Bildschirm vier Anzeigeinstrumente (`screen.number_of_gauges == 4`) präsentiert werden.

Prozedurabschnitt 2.1 – Eine Beispielproduktionsregel, die vier Unterziele (`observe_gauge_1` bis `observe_gauge_4`) aktiviert, wenn auf einem Bildschirm vier Anzeigeinstrumente präsentiert werden (`screen.number_of_gauges == 4`). Die Regel ist Teil der Prozedur des Agenten, der in Kapitel 4 vorgestellt wird.

```

rule=1, name=detect_alarms, type=regular
  Retrieve, screen
  Condition, (screen.number_of_gauges == 4)
  =>
    Goal, name=observe_gauge_1, mode=persistent, value=1.0
    Goal, name=observe_gauge_2, mode=persistent, value=1.0
    Goal, name=observe_gauge_3, mode=persistent, value=1.0
    Goal, name=observe_gauge_4, mode=persistent, value=1.0
;

```

} header

} left hand side

} right hand side

Jede Produktionsregel besteht aus drei Teilen: dem Regelkopf, der Regelbedingung oder auch **Left Hand Side (LHS)** und den Regelaktionen oder **Right Hand Side (RHS)**. Eine Produktionsregel hat eine Reihe von Attributen, die im Regelkopf spezifiziert werden können. Dabei erhält jede Regel eine eindeutige Identifikationsnummer, die für die Visualisierung und Datenaufzeichnung der Simulation wichtig ist, jedoch keinen Einfluss auf die Semantik des kognitiven Agenten hat. Das Feuern einer Produktionsregel dient immer dazu, ein bestimmtes Ziel zu erreichen. Dieses wird ebenfalls im Regelkopf angegeben. Eine Regel wird nur verwendet, wenn das angegebene Ziel in der Zielkomponente aktiv ist. Des Weiteren wird der Typ der Regel definiert. CASCaS unterscheidet vier verschiedene Regeltypen: reguläre Regeln, reaktive Regeln, Wahrnehmungsregeln und Warteregeln (s. nächster Abschnitt). Die Regelbedingung definiert den Zustand, in dem die Regel gefeuert werden soll. Streng genommen ist auch das Ziel, das im Regelkopf angegeben wird, Teil der Zustandsdefinition, da eine Produktionsregel nur gefeuert wird, wenn das angegebene Ziel aktiv ist. Die Regelbedingung formuliert Bedingungen an den Zustand der Gedächtniskomponente.

Beim Feuern einer Produktionsregel werden die Aktionen der **RHS** ausgeführt. Je nach Aktion werden Kommandos an die Gedächtnis-, Ziel- oder Motorkomponente sowie die autonome Ebene gesendet.

Eine ausführliche Beschreibung der einzelnen Elemente und ihre genaue Bedeutung sowie das Syntaxdiagramm der Prozedursprache findet sich in Anhang D.

2.3.6.2 Regelauswahl und -ausführung

Im Kern besteht die Wissensverarbeitung auf der assoziativen Ebene aus einer wiederkehrenden Abfolge von Regelauswahl und Regelausführung (s. Abbildung 2.12). Die Mindestdauer eines Schritts in diesem Zyklus beträgt 50 ms. Nachdem die Aktionen einer Produktionsregel ausgeführt sind und die minimale Zykluszeit abgelaufen ist, wird die nächste Produktionsregel ausgewählt. Hierzu wird zuerst eine Konfliktmenge an Regeln gebildet, die prinzipiell ausführbar sind. Aus dieser Menge wird schließlich eine Produktionsregel ausgewählt und ausgeführt.

CASCaS unterscheidet vier verschiedene Typen von Produktionsregeln: reguläre, reaktive, Wahrnehmungs- und Warteregeln, deren Zweck im folgenden erläutert wird. Die Art und Weise der Auswahl und Ausführung dieser Produktionsregeln unterscheidet sich. Sind mehrere Regeln unterschiedlichen Typs in der Konfliktmenge, so findet eine Priorisierung nach dem Typ statt. Reaktive Regeln haben die höchste Priorität, gefolgt von regulären Regeln, Wahrnehmungsregeln und schließlich Warteregeln.

Bei mehreren Produktionsregeln des gleichen Typs mit höchster Priorität wird eine dieser Regeln zufällig gewählt. Die Auswahl kann optional über den **strength**-Parameter im Regelkopf beeinflusst werden. Bei Angabe der Regelstärken findet eine gewichtete Auswahl auf Basis der Stärken aller Regeln mit höchster Priorität statt.

Die Besonderheiten bei der Auswahl und Ausführung der unterschiedlichen Regeltypen werden im folgenden kurz erläutert.

Reguläre Regel. Die regulären Regeln bilden typischerweise den Kern einer Prozedur. Sie beschreiben, in welchen Situationen welche Aktionen ausgeführt werden sollen, um das aktive Ziel zu erreichen. In die Konfliktmenge gelangen alle regulären Regeln, die dem aktuell aktiven Ziel zugeordnet sind und deren Gedächtniselemente auf der **LHS** alle in der Gedächtniskomponente verfügbar sind (vgl. Abschnitt 2.3.5.2). Zudem müssen alle in den **condition**-Ausdrücken angegebenen Bedingungen an diese Elemente erfüllt sein.

Reaktive Regel. Reaktive Regeln unterscheiden sich von regulären Regeln dadurch, dass sie nicht im Kontext eines bestimmten Ziels ausgeführt werden. Der **goal**-Parameter findet bei reaktiven Regeln keine Verwendung. Mithilfe von reaktiven Regeln lassen sich Reaktionen auf Situationen modellieren, die in der Bearbeitung der aktuellen Aufgabe nicht vorgesehen sind. Zur Illustration ist in Prozedurabschnitt 2.2 eine reaktive Regel abgebildet, die auf das Klingeln eines Mobiltelefons reagiert. Die abgebildete Produktionsregel benennt zwar kein Ziel im Regelkopf, dafür wird jedoch im Aktionsteil ein neues Ziel der Zielagenda hinzugefügt. Auf diese Weise lässt sich die Aufgabenstruktur eines kognitiven Modells in CASCAS auch durch ungeplante externe Ereignisse beeinflussen.

Prozedurabschnitt 2.2 – Beispiel einer reaktiven Regel, um auf einen eingehenden Anruf zu reagieren.

```
rule=1, type=reactive
Condition, (mobile_phone.sound == 'incoming call')
====>
Goal, name=answer_phone
;
```

Wahrnehmungsregel. Zur Durchführung einer Aufgabe sind typischerweise eine Reihe von Informationen nötig. Diese können vor der Durchführung bereits vorliegen oder müssen erst noch aufgenommen werden. Informationsaufnahme bedeutet dabei in vielen Fällen, dass der Blick auf eine passende Informationsquelle gerichtet wird, die die Information bereitstellt. Bei vielen Aufgaben ist daher der grundsätzliche Ablauf identisch. Zuerst werden die relevanten Informationsquellen betrachtet und dann werden passende Aktionen ausgeführt.

Sowohl der Schritt der Informationswahrnehmung als auch der Schritt der Informationsverarbeitung lassen sich in CASCAS prinzipiell durch reguläre Regeln modellieren. Da es sich hierbei jedoch um ein häufiges Muster handelt, unterstützt CASCAS die Modellierung der Informationsaufnahme durch einen speziellen Regeltyp: der Wahrnehmungsregel.

Über die regulären Regeln wird nun lediglich beschrieben, wie die Informationen genutzt werden. Für jede Information, die auf der LHS der regulären Regeln benötigt wird und die visuell aufgenommen werden kann, lassen sich Wahrnehmungsregeln angeben. Diese enthalten meistens auf der RHS lediglich ein **lookAt**-Kommando für die fehlende Information.

Wenn nun beim Aufstellen der Konfliktmenge eine reguläre Regel nicht mit in die Konfliktmenge aufgenommen werden kann, weil eine oder mehrere der zur Evaluierung der Produktionsregel nötigen Informationen nicht verfügbar sind (s. Abschnitt 2.3.5.2), so sucht CASCaS nach Wahrnehmungsregeln, die ein passendes **LookAt**-Kommando beinhalten. Diese Wahrnehmungsregeln werden der Konfliktmenge hinzugefügt, damit der Agent den Blick auf die benötigte Information richtet.

Warteregeln. Warteregeln haben die niedrigste Priorität. Sie werden daher nur gefeuert, wenn sonst keine Produktionsregel in der Konfliktmenge enthalten ist und das kognitive Modell daher keine Aktion zur Erreichung des aktiven Ziels durchführt.

Das Feuern einer Warteregeln kennzeichnet eine Unterbrechungsmöglichkeit des aktiven Ziels. Es wird in den Zustand *Selectable* versetzt, um anderen auswählbaren Zielen die Möglichkeit zu geben, bearbeitet zu werden.

2.3.7 CASCaS Fahrermodelle

Die oben beschriebene Architektur wurde in der Vergangenheit bereits genutzt, um kognitive Fahrermodelle für verschiedene Szenarien zu erzeugen. In dem vom niedersächsischen Ministerium für Wissenschaft und Kultur geförderten Projekt **IMoST**⁵ wurde mithilfe von CASCaS ein Fahrermodell für das Überholen und Einsehen auf Autobahnen entwickelt (Weber et al., 2009). Das von der EU im siebten Rahmenprogramm geförderte Projekt **ISI-PADAS**⁶ fokussierte dagegen auf den Stadtverkehr. In diesem Projekt wurde das innerstädtische Fahren hinter vorausfahrenden Fahrzeugen und das Überqueren von Kreuzungen mit Ampelanlagen bzw. das Anhalten vor den Ampeln modelliert (Wortelen et al., 2011). In beiden Szenarien wurden Aspekte des Fahrverhaltens sowohl auf der assoziativen Ebene als auch auf der autonomen Ebene modelliert. Auf der assoziativen Ebene wurde hierfür die oben beschriebene, regelbasierte Prozedursprache von CASCaS verwendet. Auf der autonomen Ebene wurde die Auswahl von Lenk- bzw. Gas- und Bremspedalbewegungen modelliert. Hierzu wurden neben kontrolltheoretischen Modellen vor allem über probabilistische Lernverfahren erstellte **Bayesian Autonomous Driver Mixture-of-Behaviors (BAD MoB)**-Modelle genutzt (Eilers und Möbus, 2013; Eilers et al., 2013).

Diese auf naiven Bayes-Netzen basierenden Modelle kommen mit wenigen Annahmen aus (Möbus et al., 2009). Unter Annahme der Markov-Eigenschaft und einer grundlegenden schematischen Struktur wird die Graphstruktur der BAD-MoB-Modelle automatisiert aus Trainingsdaten ermittelt. Dabei werden aus zahlreichen möglichen Informationsquellen diejenigen als Prädiktoren ausgewählt, die eine hohe Vorhersagekraft besitzen.

Das in Kapitel 5 vorgestellte Fahrermodell greift z. T. auf Erfahrungen aus diesen Fahrermodellen zurück. Es wurde jedoch für das Fahren auf Landstraßen ohne vorausfahrendem Verkehr entwickelt.

2.3.8 Zusammenfassung

Als Grundlage zum Verständnis der späteren Modellevaluation wurde hier die grundlegende Funktionsweise der kognitiven Architektur CASCaS erläutert. Dabei

⁵imost.informatik.uni-oldenburg.de

⁶www.isi-padas.eu

wurde vor allem auf die Wissensverarbeitung, die Wahrnehmung und die Ablaufplanung der Ziele eingegangen, da diese Aspekte von der Integration des AIE-Modells direkt betroffen sind. Für die Gedächtniskomponente und die Motorik wurden dagegen nur die grundlegenden Mechanismen beschrieben. Auch die Prozedursprache wurde nicht im Detail beschrieben. Eine weiterführende Beschreibung zur Syntax und Semantik der Prozedursprache findet sich in Anhang D.

In Kapitel 3 wird erneut auf die hier vorgestellten Konzepte eingegangen und eine Erweiterung zu CASCaS vorgestellt.

2.4 Fahrermodelle

Sowohl das in Kapitel 3 vorgestellte AIE-Modell als auch CASCaS sind Modelle, die zur Simulation von sehr unterschiedlichen Agenten genutzt werden können. Der angestrebte Anwendungskontext des AIE-Modells ist jedoch die Simulation der Aufmerksamkeitsverteilung von Autofahrern. So findet auch die Evaluation des AIE-Modells anhand eines kognitiven Fahrermodells statt.

Es existiert bereits eine Vielzahl unterschiedlichster Fahrermodelle, die sich in verschiedene nicht disjunkte Klassen einordnen lassen. An dieser Stelle soll nun eine knappe Übersicht über verschiedene Ansätze im Bereich der Fahrermodellierung mit einigen Referenzen zu weiterführender Literatur gegeben werden. Dabei wird das in dieser Arbeit verwendete Fahrermodell in diese Klassen eingeordnet.

2.4.1 Modellanwendung

Die Art der Anwendung von Fahrermodellen ist sehr unterschiedlich. Es finden sich Modelle, die zur Beschreibung, zur Analyse oder, wie in dieser Arbeit, zur Simulation des Verhaltens dienen (Bect et al., 2011).

Deskriptive Fahrermodelle beschreiben das Verhalten von Autofahrern formal oder informell. Ein solches Modell findet sich zum Beispiel in der Arbeit von McKnight und Adams (1970), in der sie das normative Verhalten für ein großes Spektrum an Verkehrssituationen detailliert aufgelistet haben.

Analytische Fahrermodelle werden genutzt, um aus dem tatsächlichen Verhalten des Fahrers Rückschlüsse auf höherwertige Informationen wie den Zustand (Müdigkeit (Krajewski et al., 2009), Ablenkung (Tango et al., 2010)) oder die Intention (Morris et al., 2011) des Fahrers zu ziehen.

Simulationsmodelle des Fahrerhaltens sind Computerprogramme, die das Verhalten von Fahrern simulieren und so in der Lage sind, ein Fahrzeug in einer Computersimulation zu steuern. In dieser Gruppe existieren sehr unterschiedliche Modelle, die zum Beispiel zur Analyse von Fahrerassistenz- und Informationssystemen (Salvucci, 2009) oder zur Untersuchung von Verkehrsflüssen (Panwai und Dia, 2005) genutzt werden. Das in dieser Arbeit entwickelte Fahrermodell stellt ebenfalls ein Simulationsmodell dar.

2.4.2 Modellannahmen

Kognitive Prozesse lassen sich nicht direkt messen, tragen jedoch zur Verhaltenserzeugung bei. Um ein Modell des menschlichen Verhaltens zu erzeugen, können in unterschiedlichem Ausmaß Annahmen zu den beteiligten kognitiven Prozessen gemacht werden.

Probabilistische Fahrermodelle machen wenige oder gar keine Annahmen über die beteiligten kognitiven Prozesse. Sie stellen direkt einen probabilistischen Zusammenhang zwischen dem Umgebungszustand und dem resultierendem Verhalten her, indem sie tatsächlich auftretende Zustände und das resultierende menschliche Verhalten beobachten. Zur Modellgenerierung können dabei verschiedene statistische Methoden verwendet werden.

Neben Simulationsmodellen wie die **BAD MoB-Modelle** (Möbus und Eilers, 2010; Eilers und Möbus, 2011b) fallen auch zahlreiche analytische Modelle in diese Kategorie, die auf verschiedene Klassifikationsalgorithmen aufbauen (z. B. Tango et al., 2010).

Kognitive Fahrermodelle machen Annahmen über nicht direkt beobachtbare interne Prozesse des Menschen, die in die Erzeugung des beobachtbaren Verhaltens involviert sind. Hierzu werden häufig kognitive Architekturen benutzt, die diese Prozesse unabhängig von einem konkreten Anwendungsfall beschreiben und es erlauben, die Implikationen des Modells in beliebigen Situationen zu evaluieren. Neben den bereits erwähnten Fahrermodellen von Salvucci (2006) und Aasmann (1995) zählen hierzu Modelle von Bi und Liu (2009), Tsimhoni und Liu (2003) und Weber et al. (2009). Auch das in dieser Arbeit entwickelte Fahrermodell zählt zu dieser Klasse.

Zudem existieren kognitive Fahrermodelle, die zwar explizite Modelle kognitiver Prozesse beinhalten, aber nicht in einer generischen kognitiven Architektur instanziiert sind, sondern ein dediziertes Softwareframework zur Simulation von Autofahrern verwenden. Hierzu zählen zum Beispiel das **Cognitive Simulation Model of the Driver (COSMODRIVE)**-Framework (Bellet et al., 2012) und das **SSDRIVE**-Framework (Cacciabue et al., 2007).

2.4.3 Zweck

Existierende Fahrermodelle sind zu verschiedensten Zwecken entwickelt worden. Einige Motivationen sollen hier aufgezeigt werden.

Psychologischer Erkenntnisgewinn. Fahrersimulationsmodelle, die auf psychologischen Theorien beruhen, lassen sich zum Beispiel nutzen, um die Implikationen der zugrunde liegenden psychologischen Theorien unter bestimmten Bedingungen simulativ zu untersuchen. Hierzu zählen zum Beispiel die Modelle von Aasmann (1995), Bellet et al. (2007) und Salvucci (2006).

Evaluierung von Fahrerassistenz- und Informationssystemen. Zur Analyse der Interaktion zwischen Fahrer und Fahrerassistenzsystemen lassen sich kognitive Fahrermodelle verwenden. Salvucci (2009) demonstrierte, wie sich auch die Interaktion mit Systemen wie Handys, die unter Umständen nichts mit der eigentlichen Fahraufgabe zu tun haben, mithilfe von Fahrermodellen untersuchen lassen. Das in dieser Arbeit entwickelte Fahrermodell soll ebenfalls zur Analyse von Fahrerassistenz- und Informationssystemen dienen. Das in Kapitel 3 konzeptionierte Aufmerksamkeitsmodell soll dabei helfen, Änderungen in der Aufmerksamkeitsverteilung der Fahrer vorherzusagen, die bei Verwendung des zu untersuchenden Fahrerassistenz- oder Informationssystems zu erwarten sind.

Unterstützung von Assistenzsystemen. Echtzeitfähige Analysemodelle lassen sich auch nutzen, um Assistenzsysteme zu entwickeln, die den aktuellen Zustand des Fahrers (z.B. Ablenkung (Tango et al., 2010), Müdigkeit

(Ji et al., 2004), (Krajewski et al., 2009)) überwachen, um die Funktionalität des Systems optimal an den Fahrer anzupassen. Dies sind daher vor allem analytische Modelle.

Untersuchung von Fahrzeugkomponenten. Simulationsmodelle lassen sich zudem nutzen, um verschiedene Fahrzeugkomponenten in vollautomatischen Simulationen zu untersuchen (MacAdam, 2001). Dies können zentrale Systeme des Fahrzeugs sein, wie Fahrwerk und Stabilisationsalgorithmen (Ungoren und Peng, 2005).

Realistische Verkehrssimulationen. Fahrermodelle können zudem genutzt werden, um Verkehrssimulationen z.B. in Fahrsimulatorexperimenten realistischer zu gestalten oder um möglichst realistische Verkehrsflüsse zu simulieren (Ma und Andréasson, 2006; Panwai und Dia, 2005). Hierbei steht jedoch das Fahrerverhalten nicht im Mittelpunkt, sondern eher das daraus resultierende Fahrverhalten des Fahrzeugs.

2.5 Beitrag zum Stand der Forschung

Das in dieser Arbeit entwickelte AIE-Modell baut auf den in diesem Kapitel beschriebenen Grundlagen auf. Es erweitert zudem den Stand der Forschung um drei Aspekte.

1. Integrierte Simulation von Aufgabenmodell und Aufmerksamkeitsverteilung.

Bisherige Aufmerksamkeitsmodelle (z. B. Senders, 1983; Carbonell, 1966; Wickens et al., 2001) simulieren lediglich die visuelle Aufmerksamkeitsverteilung. Die Interaktion mit der Umgebung wird jedoch nicht berücksichtigt. Eine Ausnahme bildet die Integration des SEEV-Modells in die kognitive Architektur MIDAS zur Steuerung der visuellen Aufmerksamkeit (Gore et al., 2009). Allerdings ist in MIDAS die Simulation der Aufmerksamkeitsverteilung unabhängig von der restlichen Verhaltenssimulation eines MIDAS-Agenten.

Das AIE-Modell soll an dieser Stelle eine detailliertere Simulation erlauben, indem einerseits das AIE-Modell – als Modell der mentalen Aufmerksamkeitsverteilung – die simultane Bearbeitung mehrerer Aufgaben in Multitasking-Situationen simulieren kann. Dadurch hängt die Aufgabenbearbeitung direkt von der Simulation der Aufmerksamkeit ab. Andererseits zeigt das AIE-Modell einen Ansatz, mit dem sich die Informationserwartung (s. SEEV-Modell) direkt aus der Simulation des Aufgabenmodells ableiten und für die Simulation der Aufmerksamkeitsverteilung nutzen lässt. Es findet dementsprechend eine enge Verknüpfung zwischen der Simulation des Aufgabenmodells und der Simulation der Aufmerksamkeitsverteilung statt.

2. Operationalisierung der Erwartung auf Basis von Ereignissen.

Viele Studien zeigten, dass Erwartung ein wichtiger Einflussfaktor für die Verteilung der Aufmerksamkeit ist (z. B. Senders, 1983; Horrey et al., 2005; Miller et al., 2004; Wickens et al., 2008). Das SEEV-Modell gibt die Erwartung als einen der zwei Top-Down-Einflussfaktoren an. Zudem wird davon ausgegangen, dass die Wahrscheinlichkeit von Umgebungseignissen die Erwartungshaltung bestimmt (Miller et al., 2004; Wickens und McCarley, 2008; Carbonell, 1966). Dennoch findet sich in der Literatur keine generelle Operationalisierung der Erwartung auf Basis der Ereignishäufigkeit. Ereignisse

werden typischerweise einzeln für jede Studie definiert (z. B. Horrey et al., 2005; Carbonell, 1966; Miller und Fu, 2007). Die Definition von Ereignissen im AIE-Modell ermöglicht dagegen eine automatische Bestimmung von Ereignissen für beliebige Situationen auf Basis eines simulierten Aufgabenmodells. Die daraus ermittelte Ereignisrate wird zur Operationalisierung der Erwartungsfaktoren verwendet.

3. Zeitabhängige Änderung der Erwartung.

Über die Ereignisrate lässt sich ein generelles Maß für die Erwartung von Ereignissen abschätzen. Dennoch kann sich die Ereigniserwartung unabhängig von der Ereignisrate innerhalb kurzer Zeiträume stark ändern (Carbonell, 1966; Miller und Fu, 2007; Bohnen et al., 1996). Ein Autofahrer, der soeben bemerkt hat, dass er schneller fährt als erlaubt und seine Geschwindigkeit dementsprechend reduziert hat, erwartet typischerweise nicht, dass die Geschwindigkeit kurz darauf wieder überschritten wird. Erst mit voranschreitender Zeit steigt die Unsicherheit über den aktuellen Zustand (Geschwindigkeit) und damit steigt auch die Erwartung eines neuen Ereignisses (Abweichung von der Zielgeschwindigkeit) (vgl. Carbonell, 1966). MIDAS berücksichtigt einen solchen Effekt bei der Verwendung des SEEV-Modells nicht. Die Erwartung bleibt in MIDAS innerhalb einer Situation immer konstant (Gore et al., 2009). Mit dem AIE-Modell wird nun ein Ansatz aufgezeigt, mit dem sich simulieren lässt, wie die Erwartung seit dem zuletzt beobachteten Ereignis ansteigt.

Die beschriebenen Aspekte erlauben detaillierte Simulationen der Aufmerksamkeitsverteilung. Dadurch lassen sich Vorhersagen zu verschiedenen Kenngrößen des Blickverhaltens machen. Das SEEV-Modell ist ein analytisches Modell der Aufmerksamkeitsverteilung, mit dem sich Vorhersagen zur prozentualen Blickverweilzeit machen lassen. Mithilfe des AIE-Modells lassen sich dagegen Blicksequenzen erzeugen. Auf dieser Basis können weitere Kennwerte wie Blickfrequenzen, Transitionswahrscheinlichkeiten oder Blickablenkungsdauern bestimmt werden, die relevant bei der Evaluation von neuen Fahrerassistenz- oder Informationssystemen im Fahrzeug sind (ISO, 2002).

Kapitel 3

Konzeptionierung des AIE-Modells

In diesem Kapitel wird das in dieser Arbeit entwickelte Adaptive Information Expectancy (AIE)-Modell beschrieben, das zur dynamischen Aufmerksamkeitssteuerung kognitiver Agenten dienen soll. Die Beschreibung erfolgt zunächst unabhängig von einer speziellen Simulationsumgebung. Die Integration in eine konkrete kognitive Architektur als Simulationsumgebung erfolgt am Ende dieses Kapitels.

Zur menschlichen Aufmerksamkeitsverteilung finden sich mehrere Modelle in der Literatur. Dies sind zum einen erklärende Modelle, die die kognitiven Mechanismen der Aufmerksamkeit beschreiben. Hierzu zählen zum Beispiel das Filtermodell von Broadbent (1958) und das Kapazitätsmodell von Kahneman (1973). Zum anderen gibt es Modelle zur Prognose der Aufmerksamkeit in konkreten Situationen. Das AIE-Modell lässt sich in diese Kategorie einordnen. Viele dieser Modelle, wie das SEEV-Modell oder Senders' Modellserie, prognostizieren über die Zeit aggregierte Eigenschaften der visuellen Aufmerksamkeitsverteilung wie prozentuale Blickverweilzeiten (PDTs) oder durchschnittliche Blickdauern.

Diese Modelle berücksichtigen häufig nur einige wenige unabhängige Variablen, die jedoch für die Aufmerksamkeitsverteilung in der jeweiligen Situation besonders relevant sind. Weitere Aspekte des menschlichen Verhaltens, die die Aufmerksamkeitsverteilung potentiell beeinflussen können, wie zum Beispiel die mentale Struktur der zu bearbeitenden Aufgabe, das Ausführen motorischer Aktionen oder Erinnerungs- und Vergessensprozesse, werden stark abstrahiert oder gar nicht berücksichtigt.

Auch die dynamische Interaktion mit der Umgebung und die dabei auftretenden Rückkopplungen werden nur selten berücksichtigt. Für viele Fragestellungen ist das jedoch vollkommen ausreichend, insbesondere wenn der Aufwand zur Prognose der Aufmerksamkeitsverteilung gering gehalten werden soll.

Um eine ganzheitlichere Sicht auf das menschliche Verhalten zu ermöglichen, die neben der Aufmerksamkeit noch weitere Aspekte berücksichtigt, ist ein anderes Vorgehen gefragt. Um beispielsweise die Interaktion mit Erinnerungsprozessen zu berücksichtigen, wird ein adäquates Gedächtnismodell benötigt, das mit dem Aufmerksamkeitsmodell kombiniert wird. Kognitive Architekturen verfolgen eben den Zweck, verschiedene Teilmodelle zu integrieren. Das resultierende Gesamtmodell ist jedoch typischerweise so komplex, dass es sich am besten durch Simulationen untersuchen lässt. Ein Simulationsmodell ermöglicht es zudem, die dynamische Interaktion mit der Umgebung zu analysieren.

Im Gegensatz zu rein analytischen Modellen ist die Anwendung von Simulationsmodellen meistens mit zusätzlichem Aufwand verbunden. Die Simulation kann dafür aber detailliertere Informationen liefern sowie zum tieferen Verständnis des menschlichen Verhaltens beitragen. Durch das komplexere Gesamtmodell können leicht Situationen auftreten, in denen die Interaktion zweier Teilmodelle zu unerwartetem Verhalten führt. Die Analyse dieser Situationen kann schließlich zu weiteren Verbesserungen des Modells führen. Auf diese Weise kann die Modellierung mithilfe von kognitiven Architekturen selbst einen Teil der Analyse darstellen.

Die Verwendung einer kognitiven Architektur zur Simulation der **visuellen Aufmerksamkeitsverteilung** ermöglicht es zudem, auf einfache Weise die Aufgabenstruktur mit zu berücksichtigen. So legen u. a. **Land und Tatler (2009)** besonderen Wert darauf, dass das Blickverhalten immer in Relation zur aktuellen Aufgabe und den dabei durchzuführenden Aktionen untersucht wird, da eine starke Wechselwirkung zwischen Aufgabe und Blickbewegungen existiert. Einerseits richtet sich die visuelle Aufmerksamkeit nach der aktuell durchzuführenden Aufgabe. So muss zum Betätigen eines Schalters, die Blick- und Handbewegung koordiniert ausgeführt werden, damit die Hand den Schalter trifft. Andererseits wird wiederum die Güte der Aufgabenbearbeitung stark durch die Aufmerksamkeitsverteilung beeinflusst. So können z. B. Autofahrer ihr Fahrzeug besser führen, wenn sie ihre Aufmerksamkeit hauptsächlich auf die Straße richten. Wenn daher menschliches Verhalten simuliert werden soll, spielt die Verteilung der Aufmerksamkeit oft eine wichtige Rolle, insbesondere in Multitasking-Situationen.

Mit dem AIE-Modell soll hier demonstriert werden, wie Wickens **SEEV-Modell** mit der Simulation regelbasierter Aufgabenmodelle kombiniert werden kann, um eine detailliertere Simulation der Aufmerksamkeit zu ermöglichen. Einige der jüngeren Simulationsmodelle der visuellen Aufmerksamkeitsverteilung, wie die Blicksteuerung in **MIDAS** oder im **A-SA-Modell**, basieren ebenfalls auf dem **SEEV-Modell**. Die Idee ist jeweils ähnlich. Während der Simulation wird der Fokus der visuellen Aufmerksamkeit von einer Informationsquelle zur anderen gerichtet. Die Wahl der Informationsquelle geschieht gewichtet nach den, in Kapitel 2 beschriebenen, vier Faktoren des **SEEV-Modells** (s. S. 26).

Einen ähnlichen Ansatz verfolgt auch das **AIE-Modell**. Es greift zudem eine Idee von **Carbonell (1966)** auf, der eines der ersten Simulationsmodelle des menschlichen Blickverhaltens erstellte (s. Abschnitt 2.1.4.2). Carbonells Modell stellt einen expliziten Zusammenhang zwischen Blickzuwendung und der zu bearbeitenden Aufgabe her. Es richtet sich vor allem nach den Eigenschaften der zu beobachtenden Informationen. So berücksichtigt es bei der Steuerung des Blickfokus die Wahrscheinlichkeit von **Ereignissen** in den zu beobachtenden Informationsquellen in Abhängigkeit vom Zustand der Informationsquelle bei der letzten Beobachtung. Die Wahrscheinlichkeit von Ereignissen und damit auch die Dringlichkeit die Informationsquelle zu betrachten, steigt mit voranschreitender Zeit seit der letzten Betrachtung kontinuierlich an. Carbonells Informationsquellen werden dabei von Anzeigeelementen gebildet, die kontinuierliche Signale liefern und seine Ereignisse sind definiert als das Überschreiten eines Schwellenwertes bei einem der Signale. Dieser Aspekt, dass die Dringlichkeit, eine Informationsquelle zu betrachten, in Abhängigkeit vom letzten Betrachtungszeitpunkt und dem Zustand der Informationsquelle zu diesem Zeitpunkt stetig ansteigt, wird vom AIE-Modell aufgegriffen.

Das AIE-Modell integriert beide Ansätze, indem es das **SEEV-Modell** als Basis zur Blicksteuerung verwendet und ein Konzept zur Operationalisierung des Erwartungsparameters des **SEEV-Modells** über menschliche Verhaltensmodelle vorschlägt. Diese Operationalisierung beruht auf Carbonells Ansatz, die Ereigniswahr-

scheinlichkeit bei der Blicksteuerung zu berücksichtigen. Das AIE-Modell generalisiert dabei die Ereignisdefinition und ist nicht auf die Beobachtung kontinuierlicher Signale beschränkt.

Im Folgenden wird in Abschnitt 3.1 umrissen, für welche Arten von Aufgaben die Simulation mit dem AIE-Modell genutzt werden kann. Es folgt die Definition des AIE-Modells. Dabei wird in Abschnitt 3.2 zuerst der generelle Kontrollmechanismus der Aufmerksamkeit auf Basis des SEEV-Modells erläutert. Daran anschließend wird in Abschnitt 3.3 die Operationalisierung der Erwartungsparameter beschrieben. Es folgen Überlegungen zur Lern- und Initialisierungsphase des AIE-Modells (Abschnitte 3.4 und 3.5). In Abschnitt 3.6 werden Grenzen des AIE-Modells und weitere, vom AIE-Modell nicht betrachtete Aspekte der Aufmerksamkeit diskutiert. Abschließend wird in Abschnitt 3.7 die Integration des AIE-Modells in die kognitive Architektur CASCaS erläutert.

Um das komplexe Thema der Aufmerksamkeitsverteilung handhaben zu können, werden im Verlauf des Kapitels eine Reihe von vereinfachenden Annahmen getroffen und erläutert. Dies wird jeweils durch eine Box am Seitenrand markiert, die die Annahme kurz wiedergibt. Alle getroffenen Annahmen werden schließlich am Ende des Kapitels zusammen aufgelistet.

3.1 Aufgabenstruktur

Wie das SEEV-Modell wird auch das AIE-Modell zur Untersuchung von Szenarien verwendet, in denen die beteiligten Personen mehrere Aufgaben gleichzeitig bearbeiten müssen, für die unterschiedliche Informationsquellen von Relevanz sind. Die Aufgaben können dabei auch Teilaufgaben einer übergeordneten Aufgabe sein, wie das Fliegen eines Flugzeugs oder das Führen eines Fahrzeugs. Solche Teilaufgaben werden typischerweise durch eine hierarchische Aufgabenanalyse (HTA - engl.: Hierarchical Task Analysis) (Annett, 2004) identifiziert.

Im Human Factors-Bereich wird die HTA häufig eingesetzt, da sie flexibel ist (Stanton et al., 2005, S.46) und helfen kann die Aufgabe in formalen Strukturen zu beschreiben (Kieras und Meyer, 2000). Die grafische Darstellung als Baum bietet zudem eine einfache Möglichkeit die Struktur intuitiv zu verbildlichen. Problematisch ist jedoch, dass die Ausformulierung der Aufgabenstrukturen stark von der Erfahrung und der Intuition des Analytikers abhängen. Stanton schrieb hierzu: "Conducting an HTA is more of an art than a science [...]" (Stanton et al., 2005, S.51).

Die Frage nach der Validität von Aufgabenmodellen ist daher stets kritisch. Es wurden verschiedene Vorgehensweisen entwickelt, um die Validität von Aufgabenmodellen zu erhöhen. Kieras und Meyer (2000) schlagen zum Beispiel eine eingrenzende Heuristik vor, bei der über theoretische Überlegungen zum Extremverhalten der tatsächliche Verhaltensspielraum eingegrenzt wird.

Generell hat sich das Identifizieren von typischen Verhaltensmustern durch eine Aufgabenanalyse jedoch als gutes Vorgehen für die Modellierung kognitiver Agenten erwiesen (Ormerod und Sheperd, 2004). Eine existierende Dekomposition der Aufgabe in Unteraufgaben ist eine Voraussetzung zur Anwendung des AIE-Modells. Die genaue Definition der Aktionen, die zum Bearbeiten einer Aufgabe durchgeführt werden müssen, spielt dabei nur eine zweitrangige Rolle.

Neben der Identifizierung von Unteraufgaben wird bei der Aufgabenanalyse auch der Ablaufplan dieser Aufgaben untersucht. Nach Annett (2004) lassen sich für

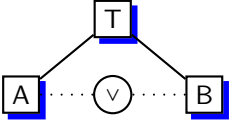
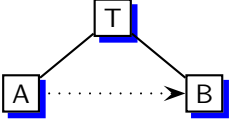
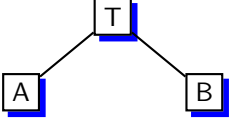
Ablaufmuster	Semantik	Grafische Notation
Alternative Bearbeitung	Entweder Aufgabe A oder Aufgabe B	
Feste Sequenz	Zuerst Aufgabe A, dann Aufgabe B	
Freie Sequenz	Aufgabe A und Aufgabe B in beliebiger Reihenfolge	

Tabelle 3.1 – Verschiedene Arten von Ablaufplänen für Unteraufgaben A und B einer Top-Level-Aufgabe T (vgl. Annett, 2004).

den Ablaufplan drei Verhaltensmuster benennen: alternative Bearbeitung, feste Sequenz und freie Sequenz (s. Tabelle 3.1). Von diesen ist für das AIE-Modell die freie Sequenz von besonderem Interesse, da diese in Situationen auftritt, in denen die Reihenfolge der Aufgabenbearbeitung nicht klar durch die Aufgabenstruktur vorgegeben ist. Um in diesen Situationen plausible Bearbeitungsreihenfolgen während einer Simulation zu erzeugen, wird das AIE-Modell verwendet. Im Folgenden wird kurz auf alle Muster eingegangen, da in komplexen Situationen die Aufgabenstruktur meistens aus einem Mix dieser Muster besteht.

Die drei Verhaltensmuster sind in Tabelle 3.1 zusammen mit der in dieser Arbeit verwendeten grafischen Notation aufgelistet, die die Hierarchie der Aufgaben wiedergibt und angelehnt ist an die hierarchische Notation der *ConcurTaskTrees* (CTTs) (Paternò, 2004). Auf Basis von CTTs wird zur Zeit in der *Model-Based User Interfaces* (MBUI) Working Group des W3C ein Standard zur Spezifikation von Aufgabenmodellen entwickelt, von dem bisher jedoch erst ein erster Entwurf vorliegt (Paternò et al., 2012). Die Knoten in den Graphen dieser Notation stellen die Aufgaben dar und sind mit dem Ziel beschriftet, das durch Bearbeiten der Aufgabe erreicht werden soll.

3.1.1 Alternative Bearbeitung

Alternative Aufgabenbearbeitungen (auch *Choice-Relationen* (Paternò, 2004; Richardson et al., 1998)) treten häufig auf. Wenn sich ein Fahrer beispielsweise einem langsameren Fahrzeug nähert, so wird er sich für eine Handlungsalternative entscheiden müssen. Er kann seine Geschwindigkeit reduzieren und dem Fahrzeug folgen oder er kann das Fahrzeug überholen. Die Entscheidung kann von weiteren Faktoren abhängen. Im genannten Beispiel kann zum Beispiel der Zeitdruck des Fahrers oder die Geschwindigkeitsbegrenzung ein solcher Faktor sein. Annett (2004) spricht daher auch von bedingter Bearbeitung.

Das AIE-Modell beschreibt nicht auf welche Weise eine Aufgabe bearbeitet wird

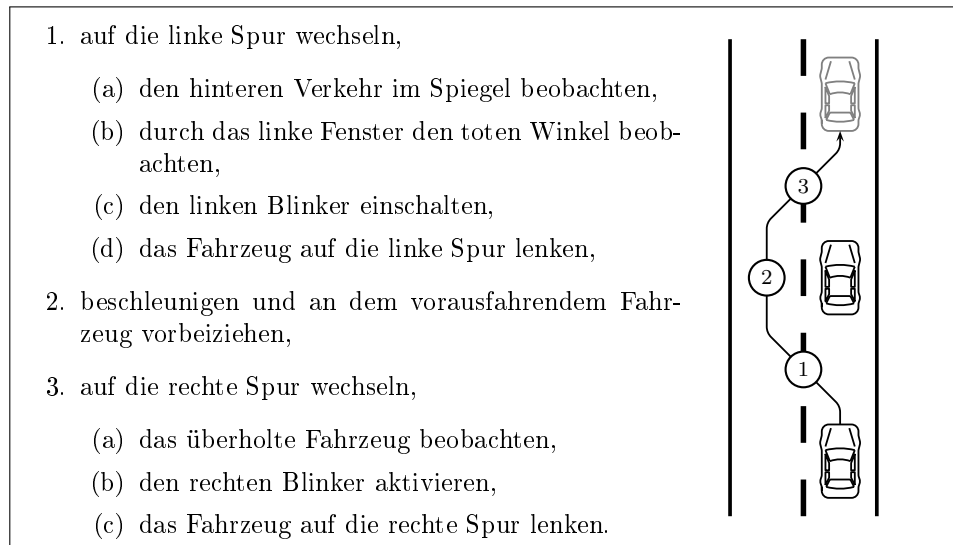


Abbildung 3.1 – Aufgabensequenz des Überholvorgangs vereinfacht nach [McKnight und Adams \(1970\)](#).

bzw. warum man sich für eine Variante der Aufgabenbearbeitung entscheidet, sondern es beschreibt, wie die Aufmerksamkeit zwischen mehreren Aufgaben verteilt wird, die aktuell bearbeitet werden. Bei der bedingten Bearbeitung mehrerer Aufgaben ist das AIE-Modell daher nicht von Relevanz, da immer nur eine Aufgabe bearbeitet wird und die Aufmerksamkeit nicht auf verschiedene Aufgaben verteilt werden muss. Eine Interaktion mit dem AIE-Modell findet erst in Kombination mit anderen Ablaufmustern statt. So kann zum Beispiel die Struktur der alternativen Unteraufgaben A oder B (s. Tabelle 3.1) wiederum aus anderen Ablaufmustern gebildet werden.

3.1.2 Feste Aufgabensequenz

Ein Beispiel für eine feste Aufgabensequenz (auch *Enabling-Relation* ([Paternò, 2004](#))) stellt das Überholen eines Fahrzeugs dar. Um diese Aufgabe zu bewältigen, muss der Fahrer eine Reihe von Unteraufgaben ausführen, die in [Abbildung 3.1](#) dargestellt sind. Die Aufgabensequenz ist einem normativen Aufgabenmodell von [McKnight und Adams \(1970\)](#) entnommen.

Diese Aufgaben sollen in dieser Reihenfolge ausgeführt werden, um das vorausfahrende Fahrzeug erfolgreich zu überholen. Zudem sollte, sobald eine Aufgabe erledigt ist, direkt die nächste Aufgabe bearbeitet werden. Die Aufgabenstruktur ist in [Abbildung 3.2](#) zu sehen. Unterhalb der Aufgabenstruktur ist ein möglicher Simulationslauf des Aufgabenmodells in einer kognitiven Architektur dargestellt. Die Boxen in der obersten Zeile bezeichnen das Ziel, das der ausgeführte kognitive Agent zum jeweiligen Zeitpunkt verfolgt. Sie repräsentieren also die mentale Aufmerksamkeit des Agenten. Die Boxen in der zweiten Zeile geben den visuellen Fokus des Agenten wieder und damit seine visuelle Aufmerksamkeit. Die Boxen in der dritten Zeile stellen schließlich motorische Aktionen des Agenten dar.

In diesem Ablaufplan sind mentaler und visueller Fokus zeitlich eng gekoppelt, so wie es häufig zu erwarten ist ([Land und Tatler, 2009](#)). Das heißt, der Agent schaut

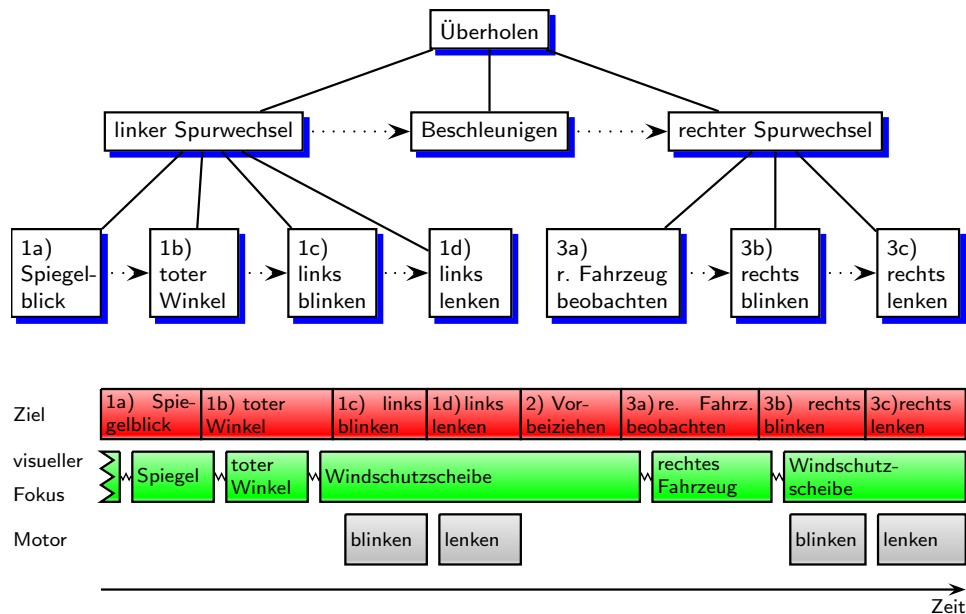


Abbildung 3.2 – Abstraktes Verhaltensmuster des Überholvorgangs. Oben: Hierarchische Aufgabenstruktur. Unten: Möglicher Simulationsablauf in einer kognitiven Architektur.

auf die Informationen, die zur Erfüllung des aktuellen Ziels benötigt werden. Dieses Modell ist abstrakt gehalten und berücksichtigt nicht alle Aspekte des Überholvorgangs. Zudem stellt es ein normatives Modell dar. In der Realität sind daher auch alternative Abläufe zu erwarten. An diesem Beispiel lässt sich jedoch die hierarchische Strukturierung sequentieller Aufgabenschritte und die starken zeitlichen Bedingungen illustrieren, die diese Ablaufpläne mit sich bringen können.

So wird zwischen Schulterblick zum toten Winkel und dem Lenken auf die linke Spur immer nur eine sehr kurze Zeitspanne sein und insbesondere wird der Schulterblick nie nach dem Lenken stattfinden, da in diesem Fall der Fahrer keine verwertbaren Informationen vom Schulterblick erwarten kann.

Allerdings sind auch diese Ablaufpläne nicht von besonderer Relevanz für das AIE-Modell, da die Reihenfolge, in der die Teilziele bearbeitet werden, starr vorgegeben ist. Ein Modell zur Aufmerksamkeitssteuerung hat hier keine Wahlmöglichkeiten und muss deterministisch das nächste Ziel der Sequenz als neuen Fokus der Aufmerksamkeit auswählen.

3.1.3 Freie Sequenz

Lässt sich keine deterministische Reihenfolge angeben, so spricht man von einer freien Sequenz (Annett, 2004) (oder auch optionalen Sequenz (Richardson et al., 1998) bzw. *Concurrent Task-Relation* (Paternò, 2004)). Dies bedeutet jedoch nicht, dass die Aufgabenreihenfolge beliebig ist. Viele Faktoren können die Wahrscheinlichkeiten einzelner Reihenfolgen beeinflussen. Dazu zählen u.a. die Parameter des SEEV-Modells, aber auch Gewohnheiten, die einzelne Individuen bei der Aufgabebearbeitung entwickelt haben (Wickens und McCarley, 2008).

Sehr häufig finden sich freie Sequenzen beim Überwachen mehrerer Informati-

onsquellen. Eine Charakteristik einer Überwachungsaufgabe ist eben das Fehlen strikter zeitlicher Bedingungen. In einer zu überwachenden Informationsquelle können prinzipiell jederzeit relevante Informationen erscheinen. Die Bearbeitung einer Überwachungsaufgabe zieht sich daher typischerweise über längere Zeiträume hin. Der Überwacher hat dabei jederzeit einen Anreiz den Blick auf die entsprechende Informationsquelle zu richten. Da dies bei Überwachungsaufgaben für mehrere Informationsquellen der Fall ist, stehen die verschiedenen Informationsquellen im Wettstreit miteinander um die visuelle Aufmerksamkeit des Überwachers.

Auch beim Autofahren nimmt der Mensch viele überwachende Aufgaben wahr (McKnight und Adams, 1970). So beobachtet er:

- das vorausfahrende Fahrzeug, um einen geeigneten Abstand zu halten,
- die Geschwindigkeitsanzeige, um eine Wunschgeschwindigkeit zu halten,
- das Navigationsdisplay, um aktuelle Informationen zur Position des eigenen Fahrzeugs zu erhalten,
- die Spiegel, um den Zustand des rückwärtigen Verkehrs zu beobachten, und
- weitere Anzeigen im Armaturenbrett (z. B. Tankfüllung, Radio, Systemstatus von Assistenzsystemen).

Die Informationen, die in den beobachteten Informationsquellen dargestellt werden, dienen verschiedenen Zielen, die über längere Zeiträume verfolgt werden. Auf diese Art von Ablaufplänen zielt das AIE-Modell ab. Bei der Steuerung der Aufmerksamkeit soll es berücksichtigen, für welches der Ziele aufgabenrelevante Informationen in einer der Informationsquellen zu erwarten sind. Hierzu ist eine Abbildung der Ziele auf die relevanten Informationsquellen nötig.

Miller (1953) gibt ein grundlegendes Schema zur generellen Beschreibung von Aufgaben an, bei dem (a) die Informationsquellen identifiziert werden, die für eine Aufgabe relevant sind, (b) der Zustand der Informationen definiert wird, bei dem reagiert werden muss, und (c) die Reaktion definiert wird, die u. U. wieder aus mehreren Teilaufgaben bestehen kann. Jede Aufgabe verfolgt dabei ein bestimmtes Ziel.

In Abbildung 3.3 ist ein Zustandsdiagramm mit mehreren Überwachungsaufgaben in diesem Schema dargestellt, wobei g_i das Ziel der Überwachung bezeichnet und AOI_i die Informationsquelle mit den aufgabenrelevanten Informationen. Der Zustand der Informationsquelle, bei dem eine Reaktion des Überwachers nötig ist, ist als ein boolescher Ausdruck c_i definiert. Die Negation bildet genau jene Zustände ab, in denen keine relevanten Informationen in der Informationsquelle angezeigt werden. Insgesamt wird eine Menge G von n Zielen überwacht.

Um die Beschreibung des AIE-Modells einfach und übersichtlich zu halten, soll vorerst davon ausgegangen werden, dass für jede Aufgabe genau eine Informationsquelle relevant ist und umgekehrt eine Informationsquelle genau einer Aufgabe Informationen liefert. Das AIE-Modell kann jedoch auch in komplexeren Situationen verwendet werden. In Abschnitt 3.6.3.1 wird das Verhalten des AIE-Modells ohne diese Restriktionen diskutiert.

Für jedes Ziel werden durch Betrachten der betreffenden Informationsquelle die benötigten Informationen akquiriert. Es folgt die Beurteilung der Relevanz, die durch c_i definiert ist. Hierbei wird entschieden, ob ein Eingreifen basierend auf den wahrgenommenen Informationen notwendig ist oder nicht. Dieser Ablauf wird wiederkehrend in beliebiger Reihenfolge der Ziele durchgeführt.

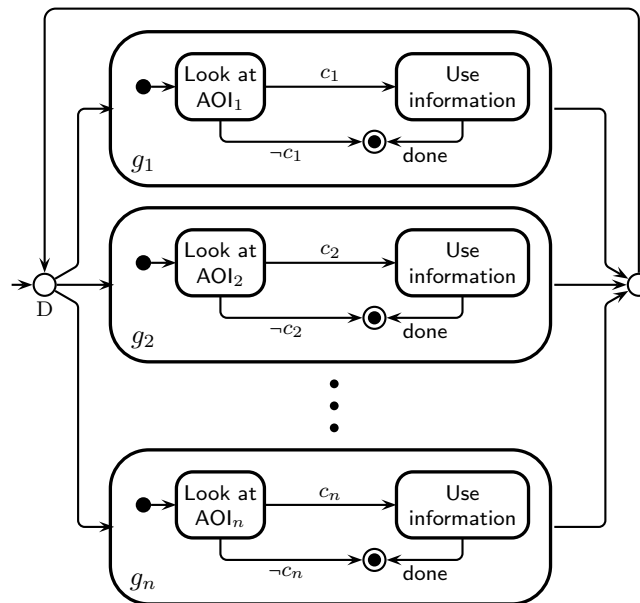


Abbildung 3.3 – UML-Zustandsdiagramm von n Aufgabenzielen in freier Sequenz. Am Entscheidungspunkt D wird entschieden, welches Aufgabenziel als nächstes bearbeitet wird.

Wichtig für das AIE-Modell in diesem Diagramm ist der Entscheidungspunkt D (links in der Abbildung), an dem ausgewählt wird, auf welches Ziel die Aufmerksamkeit als nächstes gerichtet wird. Um den dargestellten Automaten zu simulieren, muss jedes Mal, wenn die Simulation den Entscheidungspunkt erreicht, ein konkretes Ziel zur Bearbeitung ausgewählt werden. Nachdem eine Aufgabe bearbeitet wurde, gelangt das Modell erneut an den Entscheidungspunkt D und wählt das nächste Aufgabenziel aus. Das AIE-Modell liefert die Basis für diese Entscheidung. Das AIE-Modell berücksichtigt für die Aufmerksamkeitssteuerung nur Ziele, die in freier Sequenz ausgeführt werden. Um die Modellbeschreibung übersichtlich zu halten, wird vorerst davon ausgegangen, dass lediglich Ziele in freier Sequenz vorliegen. Bei komplexen Aufgaben treten typischerweise aber alle drei vorgestellten Ablaufmuster auf. Dies ist keine Einschränkung für die Anwendung des AIE-Modells. In Abschnitt 3.6.3.2 wird beschrieben, wie sich das AIE-Modell in komplexere Aufgabenstrukturen einbetten lässt. In Abschnitt 3.7 wird zudem demonstriert, wie bei der Integration des Modells in eine konkrete kognitive Architektur die verschiedenen Ablaufmuster gemeinsam in einer [Aufgabenprozedur](#) verwendet werden können.

3.2 Zielauswahl

Im Folgenden wird im Detail erläutert, auf welche Weise das AIE-Modell die Zielauswahl vornimmt. Die verschiedenen Algorithmen die dabei beschrieben werden, sind als Pseudocode mit einer formalen Semantik in komprimierter Form in Anhang A abgebildet.

Als Basis zur Auswahl eines Ziels dient die SEEV Formel (s. Gleichungen 2.5 und 2.7, S. 26 und 29). Für das AIE-Modell werden jedoch nur die Top-Down-Faktoren *Wert* und *Erwartung* berücksichtigt. Dies entspricht dem erwarteten Gewinn, den die

Zuwendung der Aufmerksamkeit auf ein bestimmtes Ziel verspricht (Moray, 1986). Rational betrachtet sollte sich ein Überwacher nach diesen Faktoren richten, um eine Aufgabe möglichst optimal zu bearbeiten (Wickens und McCarley, 2008, S.50). Die anderen beiden Faktoren (*Auffälligkeit* und *Aufwand*) können prinzipiell kontraproduktiv auf die Aufgabenbearbeitung wirken, wenn beispielsweise wichtige Informationen unauffällig oder schwer erreichbar sind (Wickens und McCarley, 2008). Bei alltäglichen Aufgaben ist zu erwarten, dass die Top-Down-Faktoren eine dominierende Rolle spielen, da aufgrund der Erfahrung bekannt ist, wie wichtig einzelne Informationen sind und wann diese Informationen zu erwarten sind. Auch für viele Autofahrer ist das Autofahren eine alltägliche Aufgabe. Zwei Studien, die den Einfluss des *Aufwands* bei Autofahrern (Horrey et al., 2005) und bei Piloten (Wickens et al., 2003b) untersuchten, konnten keinen hemmenden Einfluss des *Aufwands* bei Piloten und nur eine schwache Andeutung bei Autofahrern nachweisen. In beiden Studien wurde die räumliche Lage der Informationsquellen zur Bestimmung des *Aufwands* herangezogen. Diese Ergebnisse deuten darauf hin, dass sich Autofahrer und Piloten stärker an den Top-Down-Faktoren ausrichten. Das AIE-Modell berücksichtigt nur diese Faktoren.

Im Zusammenhang mit dem AIE-Modell wird im weiteren Verlauf für den Erwartungsfaktor aus Gleichung 2.5 (S. 26) das Symbol u verwendet und für den Wertfaktor das Symbol v . Der anwendungsspezifische Anteil der Erwartungs- und Wertparameter wird durch die Kleinbuchstaben u bzw. v dargestellt, während das generelle Gewicht der Einflussfaktoren durch die Großbuchstaben U bzw. V angegeben wird.

Um die Zielauswahl zu steuern, betrachtet das AIE-Modell alle Ziele, die in freier Sequenz ausgeführt werden können. Die Menge dieser Ziele wird mit G bezeichnet. Für jedes Ziel $g_i \in G$ wird auf Basis der Erwartungs- und Wertparameter ein Gewicht $w(g_i)$ ermittelt, das beschreibt, wie stark der Drang danach ist, die Aufmerksamkeit auf das Ziel g_i zu richten. Angelehnt an den von Bundesen (1990) geprägten Begriff *Attentional Weight* wird $w(g_i)$ im Weiteren als das *Aufmerksamkeitsgewicht* von g_i bezeichnet. Es wird wie folgt berechnet:

$$w(g_i) = U \cdot \frac{u_{g_i}}{\sum_{g_j \in G} u_{g_j}} + V \cdot \frac{v_{g_i}}{\sum_{g_j \in G} v_{g_j}} \quad (3.1)$$

Die Erwartung neuer Informationen in der Informationsquelle von g_i wird durch u_{g_i} und der Wert der Aufgabe durch v_{g_i} ausgedrückt.

3.2.1 Normierung

In Gleichung 3.1 ist zu sehen, dass die Erwartungs- und Wertparameter (u_{g_i} und v_{g_i}) in den Bereich $[0..1]$ normiert werden, indem sie durch die Gesamtsumme aller Erwartungs- bzw. aller Wertparameter geteilt werden. Eine Normierung ist im ursprünglichen SEEV-Modell nicht vorgesehen, für das AIE-Modell ist sie jedoch notwendig. Das wird ersichtlich, wenn man die Operationalisierung der SEEV-Parameter bei bisherigen Anwendungen in der Literatur vergleicht mit derjenigen, die hier für das AIE-Modell verwendet werden soll. Wickens schlug für die Operationalisierung aller vier Parameter das gleiche Verfahren vor. Er verwendete hierzu den Lowest-Ordinal-Algorithmus (s. Abschnitt 2.1.4.3). Dies führt dazu, dass alle Einflussfaktoren einen ähnlichen Wertebereich aufweisen, so dass kein Einflussfaktor bevorzugt wird. Das AIE-Modell verwendet dagegen unterschiedliche Operationalisierungen für die Erwartungs- und Wertparameter. Dies wird in den nachfolgenden

Abschnitten zur Operationalisierung verdeutlicht. Die Erwartungsparameter werden beim AIE-Modell automatisch bestimmt und können je nach Szenario unterschiedliche Wertebereiche haben. Die Wertparameter müssen dagegen von Domänenexperten bestimmt werden. Hierbei ist es hilfreich, reale Größen wie monetären Gewinn oder Risikomaße als *Proxy* zu verwenden. Beispiele für dieses Vorgehen finden sich bei [Byrne und Kirlik \(2004\)](#) und [Fleetwood \(2005\)](#).

Durch die unterschiedlichen Operationalisierungen ergeben sich unterschiedliche Wertebereiche für die Einflussfaktoren. Würde keine Normierung vorgenommen werden, so würde der Einflussfaktor mit den durchschnittlich größeren Parameterausprägungen den Wert von $w(g_i)$ stärker bestimmen als der andere Einflussfaktor. Durch die Normierung ist dagegen die Gesamtsumme aller Aufmerksamkeitsgewichte gleich $U \cdot 1 + V \cdot 1$. Wie stark der Einfluss der Erwartungs- bzw. Wertparameter ist, wird daher lediglich über die dafür vorgesehenen Gewichte U und V bestimmt. Die Problematik der Normierung tritt auch bei der Verwendung des *SEEV*-Modells in *MIDAS* auf ([Gore et al., 2009](#)). *MIDAS* löste es jedoch, indem es die Parameterausprägungen auf ähnliche Bereiche einschränkt. Die Parameter für *Aufwand* werden automatisch bestimmt im Bereich $[0..1]$. Die Parameter für die *Auffälligkeit* können die Ausprägungen $\{1, 2, 3, 4\}$ annehmen. Dem Modellierer werden hierzu Regeln als Heuristik zur Bestimmung der Parameterausprägung bereitgestellt. Für die Erwartungs- und Wertparameter kann aus den Ausprägungen $\{\text{none} = 0, \text{low} = 0.333, \text{moderate} = 0.666, \text{high} = 1\}$ gewählt werden. Somit sind die Wertebereiche in *MIDAS* vorab bekannt.

Die Normierung des AIE-Modells hat einen ähnlichen Effekt. Soll nun dennoch in bestimmten Szenarien ein Einflussfaktor ein stärkeres Gewicht erhalten als der andere, so kann dies unabhängig von der Informationsquelle über die Gewichtungsfaktoren U und V angegeben werden.

3.2.2 Auswahlwahrscheinlichkeit

Die über Gleichung 3.1 berechneten Aufmerksamkeitsgewichte der Ziele werden gemäß dem Choice Axiom von [Luce \(1959\)](#) verwendet, um die Auswahlwahrscheinlichkeit von g_i am Entscheidungspunkt D (Abbildung 3.3) zu ermitteln:

$$P(g_i) = \frac{w(g_i)}{\sum_{g_j \in G} w(g_j)} \quad (3.2)$$

In Gleichung 3.1 ist der Zusammenhang der Erwartungs- und Wertparameter additiv angegeben. In der Literatur findet sich jedoch sowohl die additive Verknüpfung der Einflussfaktoren ([Gore et al., 2009](#); [Wickens et al., 2008](#)), als auch die multiplikative ([Horrey et al., 2006, 2005](#); [Wickens et al., 2001, 2003a](#); [Steelman-Allen, 2011](#); [Fleetwood, 2005](#)). Im Folgenden wird vorerst von der additiven Formulierung ausgegangen. Die Frage, welche Formulierung die geeignetere ist, wird in den nachfolgenden Kapiteln näher beleuchtet. Die Wahl der Formulierung hat allerdings einen Einfluss auf die Gewichtungsfaktoren U und V . Bei der additiven Formulierung lässt sich Gleichung 3.2 schreiben als:

$$P(g_i) = \frac{\frac{U}{V} \cdot \frac{u_{g_i}}{\sum_{g_j \in G} u_{g_j}} + \frac{v_{g_i}}{\sum_{g_j \in G} v_{g_j}}}{\frac{U}{V} + 1} \quad (3.3)$$

Die Herleitung der Formel findet sich in Anhang E. Bei dieser Formulierung treten U und V nur noch im direkten Verhältnis zueinander auf. Das bedeutet, dass die

absoluten Werte der Gewichtungsfaktoren nicht von Interesse sind, sondern nur ihr Verhältnis zueinander. Die Gleichung 3.1 mag daher irreführend zu der Annahme verleiten, dass U und V zwei freie Parameter des AIE-Modells sind. Tatsächlich gibt es jedoch nur den einen freien Parameter $\frac{U}{V}$.

Bei der multiplikativen Formulierung hat die Wahl von U und V jedoch keinen Effekt auf die Auswahlwahrscheinlichkeit der Ziele, da sich U und V in Gleichung 3.2 wegekürzen (s. Anhang E).

3.2.3 Vergleich zu bestehenden Simulationsmodellen

Der dargestellte Ansatz zur Simulation der Aufmerksamkeit wurde auf ähnliche Weise auch genutzt, um das SEEV-Modell sowohl in das A-SA-Modell (Wickens et al., 2008) als auch in die Aufmerksamkeitssteuerung von MIDAS 5.0 (Gore et al., 2009) zu integrieren. Die grundsätzliche Idee findet sich aber schon in einer von Senders' Modellvarianten, dem Random Constraint Model (RCM) (Senders, 1983), jedoch mit der Einschränkung, dass lediglich die Erwartung und nicht der Informationswert berücksichtigt wird. Zudem benennt es nicht explizit die Erwartung, sondern bezieht sich auf die Bandbreite, die eine Ursache für die Erwartung von Ereignissen ist (Wickens et al., 2001; Wickens und McCarley, 2008).

Diese drei Ansätze unterscheiden sich im Detaillierungsgrad der Simulation. Senders führt keine Simulation durch, sondern schließt analytisch auf Basis seines Modells auf aggregierte Werte, wie durchschnittliche Blickfrequenzen und -dauern.

Das A-SA-Modell wird genutzt, um tatsächlich die Aufmerksamkeit in konkreten Situationen zu simulieren. Viele andere Aspekte des menschlichen Verhaltens werden jedoch nicht berücksichtigt. Insbesondere greift das A-SA-Modell nicht aktiv in die Umgebung ein. So ist beispielsweise nicht vorgesehen, dass das A-SA-Modell für einen Piloten ein simuliertes Flugzeug selbstständig fliegt.

Diesen Schritt geht dagegen MIDAS. MIDAS als kognitive Architektur beinhaltet Modelle zu weiteren Aspekten menschlichen Verhaltens. Daher sind in MIDAS instantiierte Modelle in der Lage, aktiv mit ihrer Umgebung zu interagieren.

Das AIE-Modell zielt ebenfalls auf diese Klasse von Anwendungen ab, bei der eine ausführbare Beschreibung der Aufgaben vorhanden ist. Im Gegensatz zur Verwendung des SEEV-Modells in MIDAS bietet das AIE-Modell jedoch eine Operationalisierung der Erwartungsparameter, die auf der Simulation der Aufgabenprozedur basiert. Dies wird im folgenden Abschnitt dargestellt.

3.3 Operationalisierung der Modellparameter

Um das beschriebene Modell der Aufmerksamkeitssteuerung anzuwenden, müssen konkrete Werte für die einzelnen Parameter vorhanden sein. Bei der Operationalisierung dieser Parameter finden sich in der Literatur unterschiedliche Ansätze.

Senders beschränkte sich bei den Informationsquellen auf analoge Anzeigeelemente, die kontinuierliche Signale wiedergeben. Das RCM-Modell von Senders definiert die Erwartung direkt über die Bandbreite des zugrunde liegenden Signals.

Bei Verwendung des SEEV-Modells — sei es integriert im A-SA-Modell oder nicht — wird typischerweise der Lowest-Ordinal-Algorithmus eingesetzt (Horrey et al., 2005; Wickens et al., 2001, 2003a, 2008). Fleetwood (2005) verwendete dagegen Proxy-Variablen zur Operationalisierung. Bei seinen Untersuchungen bestand die Aufgabe der Probanden darin, während der Interaktion mit der Laboraufgabe eine

hohe Punktzahl zu erzielen. Er nutzte die Alarmrate als **Proxy** für die Erwartung und die Punktzahl für den Informationswert.

Steelman-Allen (2011) ließ die Parameter dagegen durch Domänenexperten bestimmen. Dieses Vorgehen wird auch von **MIDAS** genutzt (**Gore et al., 2009**).

Bei der Bestimmung der Wertparameter des AIE Modells wird vorgeschlagen, die bestehenden Verfahren zu verwenden, wie den **Lowest Ordinal Algorithmus** oder die Bestimmung durch Domänenexperten. Für die Ermittlung der Erwartungsparameter präsentiert das AIE-Modell jedoch einen neuen Ansatz. Sie werden dynamisch bestimmt basierend auf **Ereignissen**, die während der Simulation auftreten.

3.3.1 Ereignisse

Wickens beschreibt den Erwartungsparameter als "*information-related measure of event expectancy (e.g., bandwidth, event rate; [...])*" (**Wickens et al., 2001**, S.3). Er gibt jedoch nur beispielhaft **Bandbreite** und **Ereignisrate** als Operationalisierung für den Erwartungsparameter an. Er nennt zudem noch Hinweise aus der Umgebung, wie beispielsweise Warnsignale, die ebenfalls Ursache für eine erhöhte Erwartung von **Ereignissen** sein können (**Wickens und McCarley, 2008**). Um eine plausible Rangordnung für den **Lowest-Ordinal-Algorithmus** zu erstellen, ist die etwas vage Beschreibung in vielen Fällen sicherlich ausreichend.

Den Ansatz, die **Bandbreite** eines Signals zur Operationalisierung zu verwenden, nutzte bereits Senders in seinen Modellen. Bemängelt wurde an den Modellen unter anderem, dass sie nicht berücksichtigen, dass in vielen Situationen der Beobachter die Signale aktiv beeinflussen kann und wird (**Carbonell, 1966**). Dies tritt üblicherweise bei sogenannten Tracking-Aufgaben auf, bei denen der Beobachter bestimmte Variablen in einem Zielbereich halten muss. Ein typisches Beispiel beim Autofahren ist das Halten des Fahrzeugs innerhalb der Spur und das Einhalten der erlaubten Höchstgeschwindigkeit bzw. der Wunschgeschwindigkeit.

Bei Senders' Experimenten treten Ereignisse dann ein, wenn das Signal eines Anzeigeelements einen Schwellenwert überschreitet. Es wird jedoch angenommen, dass der Schwellenwert für alle Anzeigeelemente gleich ist. Dies ist in realen Anwendungen typischerweise nicht der Fall. Welchen Schwellenwert ein Beobachter verwendet und auf welche Weise er mit dem System interagiert, hängt von der zu bearbeitenden Aufgabe ab.

Ein weiterer Kritikpunkt an Senders' Modellen wurde bereits in Abschnitt 2.1.4.1 genannt und betrifft die Aussagekraft von Umgebungsreizen. **Miller et al. (2004)** konnten zeigen, dass mit wachsender Erfahrung die Güte der Aufgabenbearbeitung nicht von der Signalbandbreite, sondern wesentlich stärker von der Ereignisrate bestimmt wird, die für den Beobachter das eigentliche Kriterium zum erfolgreichen Bearbeiten der Aufgabe ist. Auch Carbonells Modell (s. Abschnitt 2.1.4.2) verfolgt die Idee, dass sich die visuelle Aufmerksamkeit nach der Ereigniswahrscheinlichkeit richten sollte.

Diesem Gedanken folgend wird für das AIE-Modell die Operationalisierung der Erwartung basierend auf der aufgetretenen Ereignisrate durchgeführt. Zur Bestimmung der Ereignisrate wird eine existierende, ausführbare Beschreibung der Aufgabe vorausgesetzt.

Ausgehend von Robert Millers (1953) genereller Aufgabenbeschreibung (s. Abbildung 3.4) wird ein Ereignis als das aufgabenabhängige Reagieren auf relevante Informationen definiert. Als relevant werden Informationen bezeichnet, wenn sie eine boolesche Bedingung c erfüllen. Diese beschreibt, in welchen Situationen ein Handeln des Überwachers nötig ist, um das Aufgabenziel zu erreichen. Die Bedin-




Abbildung 3.4 – Abstraktes Schema zum Bearbeiten einer Aufgabe. Ein Ereignis e tritt auf, wenn zum Bearbeiten der Aufgabe Informationen genutzt werden, die zum Erreichen des Ziels g einer Aufgabe benötigt werden. Die Bedingung c gibt an, wann diese Informationen vorliegen.

gungen sind Teil des Aufgabenmodells und sollten während der Aufgabenanalyse ermittelt werden.

Definition 4 (Ereignis)

Werden zum Zeitpunkt t Informationen, die zum Erreichen eines Ziels g von Relevanz sind, genutzt, um dieses Ziel zu erreichen, so wird von einem Ereignis $e = (g, t)$ gesprochen. Bezeichne E alle während einer Simulation aufgetretenen Ereignisse. Mit E_g werden alle Ereignisse aus E bezeichnet, die dem Ziel g zugeordnet werden.

Ereignisse lassen sich chronologisch ordnen und indizieren. Mit $e_{g,i}$ wird im Weiteren das i -te Ereignis aus E_g bezeichnet.

Diese sehr generelle Definition erlaubt es, Ereignisse sowohl auf der Basis von einfachen diskreten Informationen, wie dem Zustandswechsel einer Ampel von grün zu gelb, als auch auf Basis kontinuierlicher Variablen zu definieren, wie zum Beispiel der Änderung des Abstandes zu einem vorausfahrenden Fahrzeug. Auch die Kombination mehrerer Variablenausprägungen ist möglich.

3.3.2 Ereignisrate

Mit der Definition von Ereignissen lässt sich nun auch die Ereignisrate für ein Ziel angeben. Eine erste intuitive Definition lässt sich geben, indem man die Anzahl der Ereignisse in E_g durch die Gesamtsimulationszeit teilt. Problematisch an der Definition ist jedoch, dass bei längeren oder komplexeren Simulationen situationsabhängig nicht zu jedem Zeitpunkt alle Ziele aktiv sind.

Beim Autofahren wird man beispielsweise dem Ziel, einem vorausfahrenden Fahrzeug zu folgen, nur dann nachgehen, wenn auch tatsächlich ein vorausfahrendes Fahrzeug vorhanden ist. Situationsabhängig werden also unterschiedliche Ziele verfolgt. Es ist daher sinnvoll, die Anzahl der Ereignisse für ein Ziel nicht in Relation zur Gesamtsimulationszeit zu setzen, sondern nur zur gesamten Zeitdauer, in der das Ziel aktiv war. Diese Dauer wird mit d_g bezeichnet. Die Ereignisrate r_g für ein Ziel g ergibt sich dann durch:

$$r_g = \frac{|E_g|}{d_g} \quad (3.4)$$

3.3.3 Ereigniswahrscheinlichkeit

Sind lediglich die Ereignisraten der einzelnen Ziele bekannt, dann ist zum Zeitpunkt t die Wahrscheinlichkeit, dass das nächste Ereignis, dem Ziel g zugeordnet werden

kann, das Verhältnis von r_g zur Gesamtereignisrate aller aktiven Ziele:

$$P((g, t_{\text{next}}) \in E) = \frac{r_g}{\sum_{k=1}^n r_k} \quad (3.5)$$

Dabei bezeichnet $t_{\text{next}} = \min\{t^* \mid (g, t^*) \in E, t^* > t\}$ den Zeitpunkt des nächsten Ereignisses für ein beliebiges Ziel. Die Ereignisrate bestimmt demnach, wie häufig ein Überwacher Ereignisse in einer Informationsquelle erwarten kann. Aus dieser Sicht ist es plausibel, den Erwartungsparameter in Gleichung 3.1 direkt durch die Ereignisrate zu operationalisieren:

1. Operationalisierungsvariante des Erwartungsparameters:

$$u_g := r_g \quad (3.6)$$

Das bedeutet, dass für das AIE-Modell der Erwartungsanteil in Gleichung 3.1 (S. 69) durch das Verhältnis der Ereignisraten der verschiedenen Ziele bestimmt wird. In einem Review mehrerer Experimente zeigen [Peterson und Beach \(1967\)](#) auf, dass Menschen tatsächlich gut in der Lage sind Verhältnisse von Ereignishäufigkeiten zu schätzen.

In verschiedenen Studien (z. B. [Senders, 1964](#); [Miller et al., 2004](#); [Horrey et al., 2005](#); [Wickens et al., 2001](#)) wurde zudem demonstriert, dass das Blickverhalten der Probanden stark durch die Ereignisrate beeinflusst wird und sich diese in den jeweils untersuchten Situationen gut dazu eignet, um durchschnittliche [Blickfrequenzen](#) und prozentuale Blickverweilzeiten zu prognostizieren. Das bedeutet jedoch nicht, dass sich damit auch plausible Blicksequenzen simulieren lassen. Ziel des AIE-Modells ist nicht nur die Vorhersage von Werten, die über längere Zeiträume aggregiert wurden, sondern auch die Erzeugung von plausiblen Verhalten, das zu eben diesen aggregierten Werten führt. Daher wird eine detailliertere Operationalisierung angestrebt.

Betrachtet man kleinere Zeiträume, so finden sich in vielen Anwendungsszenarien weitere Informationen, mit denen der menschliche Beobachter die unmittelbar nächsten Ereignisse vorhersagen kann. Ein typisches Beispiel sind Fortschrittsbalken bei grafischen Nutzungsoberflächen, die genau zu dem Zweck da sind, eine Abschätzung der verbleibenden Zeit zu geben. Über den Wert des beobachteten Signals (prozentualer Fortschritt eines Prozesses) und die Geschwindigkeit des Signals lässt sich auf den Zeitpunkt des erwarteten Ereignisses (Abschluss des beobachteten Prozesses) schließen. Diese Art von Information kann potentiell die Erwartung beim Beobachter vergrößern oder verringern und damit die Aufmerksamkeit situationsabhängig leiten. [Bohnen et al. \(1996\)](#) zeigten, dass dieser Effekt auch bei [Senders Versuchsaufbau](#) (s. Abschnitt 2.1.4.1) auftritt. In ihrem Experiment, war der Zeitraum zwischen zwei Blicken zum gleichen Instrument kleiner, je näher an der Alarmregion sich der Zeiger des Instrumentes beim ersten Blick befand. Der Abstand des Zeigers zur Alarmregion ist in dem Szenario somit eine Information die die Erwartung des nächsten Ereignisses (Alarm) beeinflusst.

[Senders \(1983\)](#) drei Varianten des Conditional Sampling Models versuchen diesen Aspekt zu berücksichtigen, lassen sich aber wiederum nur auf Situationen anwenden, bei denen der Beobachter nicht in den beobachteten Prozess eingreifen kann. Oftmals kann der Überwacher jedoch aktiv eingreifen. Ein typisches Beispiel sind Nachführungs- bzw. Tracking-Aufgaben, bei denen der überwachte Wert innerhalb eines Sollbereichs gehalten werden muss. Beim Autofahren sind das Halten




Abbildung 3.5 – Ereignisabstände (Δt) werden für jeweils zwei aufeinanderfolgende Ereignisse desselben Ziels definiert.

des Fahrzeugs in der Spur und das Abstandhalten Tracking-Aufgaben. Carbonell (1966) geht auf diesen Aspekt ein und entwickelte basierend auf Senders Conditional Sampling Modellen ein Queuing-Modell, das korrigierendes Eingreifen des Beobachters bei Tracking-Aufgaben berücksichtigt.

Auch der Zeitpunkt des letzten Ereignisses kann ein Prädiktor für den nächsten Ereigniszeitpunkt sein. Normalerweise ist die Dynamik des beobachteten Systems nicht rein durch Zufall bestimmt, sondern folgt einem bestimmten Prozess, der sich unter anderem in typischen Ereignisabständen widerspiegelt. Miller und Fu (2007) konnten in einer Laborstudie zeigen, dass die Versuchspersonen sogar ganze Ereignismuster in den Ereignissequenzen erkennen und nutzen konnten, um ihr Blickverhalten zu optimieren.

Von all den beschriebenen Aspekten, die die Erwartung von Ereignissen beeinflussen können, konzentriert sich das AIE-Modell vor allem auf die typischen Ereignisabstände. Dies geschieht, indem während der Simulation die Abstände zwischen zwei aufeinanderfolgenden Ereignissen $e_{g,i} = (g, t_i)$ und $e_{g,i+1} = (g, t_{i+1})$ für dasselbe Ziel aufgezeichnet werden (s. Abbildung 3.5):

$$\Delta t_{g,i} = t_{i+1} - t_i \quad (3.7)$$

Mit h_g wird die Häufigkeitsverteilung der aufgezeichneten Ereignisabstände für das Ziel g bezeichnet. Dann lässt sich für jedes Ziel g eine **kumulierte Häufigkeitsverteilung** H_g der Ereignisabstände erstellen. Im Folgenden soll nun gezeigt werden, wie sich über H_g eine Operationalisierung des Erwartungsparameters durchführen lässt, die für ein Simulationsmodell der Aufmerksamkeitsverteilung besser geeignet erscheint als die reine Ereignisrate aus Gleichung 3.6.

Über den Wert $H_g(\Delta t)$ lässt sich die Frage beantworten, wie häufig ein Ereignis spätestens Δt Zeiteinheiten nach dem vorherigen Ereignis aufgetreten ist. Diese Frage ist insbesondere in Situationen interessant, in denen die Informationen, die in einer Informationsquelle ein Ereignis definieren, für längere Zeit angezeigt werden. Das ist bei vielen Tracking-Aufgaben der Fall. Das zu kontrollierende System korrigiert das Überschreiten eines Threshold typischerweise nicht selbstständig, sondern es ist ein Eingreifen des Operators nötig. Ohne einen korrigierenden Eingriff nimmt die Abweichung mit fortschreitender Zeit tendenziell eher zu (Carbonell et al., 1968). Dies ist auch beim Spur- und Abstandhalten der Fall.

Auch viele Informations- und Statusanzeigen, wie Warnleuchten für niedrigen Öl- oder Benzinfüllstand, oder Staumeldungen des Navigationssystems werden nicht einmalig beim Erkennen angezeigt, sondern werden dauerhaft in der Informationsquelle präsentiert.

Kennt ein Beobachter die Verteilung der Ereignisabstände, so kann er das Wissen über den Zeitpunkt des letzten Ereignisses für eine Aufgabe nutzen, um seine Auf-

merksamkeit optimal zu verteilen, indem er seine Aufmerksamkeit nach den beobachteten Häufigkeiten ausrichtet. Das AIE-Modell nutzt diese Information ebenfalls. Hierzu definiert es für jedes Ziel eine Ereignisfunktion.

Definition 5 (Ereignisfunktion)

Für ein Aufgabenziel g wird die durch die Simulationszeit von g geteilte *kumulierte Häufigkeitsverteilung* der Ereignisabstände als *Ereignisfunktion* von g bezeichnet.

$$ef_g(\Delta t) = \frac{H_g(\Delta t)}{d_g} \quad (3.8)$$

Wie auch in der ersten Operationalisierungsvariante über die Ereignisraten wird hier eine Normierung durchgeführt über die Zeitdauer d_g , für die das Ziel g aktiv war, um unterschiedlich lange Aktivitätszeiten der Ziele zu berücksichtigen. Mittels der Ereignisfunktionen lässt sich der Erwartungsparameter in Gleichung 3.1 nun zeitabhängig operationalisieren.

Zu einem Simulationszeitpunkt t ist der Zeitpunkt des letzten für g beobachteten Ereignisses gegeben durch:

$$t_{g,\text{prev}} = \max\{t^* \mid (g, t^*) \in E, t^* < t\} \quad (3.9)$$

Nun lässt sich u_g zum Zeitpunkt t wie folgt bestimmen.

2. Operationalisierungsvariante des Erwartungsparameters:

$$u_g(t) = ef_g(t - t_{g,\text{prev}}) \quad (3.10)$$

Für die Simulation der Aufmerksamkeit lassen sich mit dieser Variante der Operationalisierung gegenüber Gleichung 3.4 und 3.6 einige Vorteile erhoffen. Die Ereignisrate r_g wird über längere Zeiträume bestimmt. Bei reiner Berücksichtigung der Ereignisraten wird daher lediglich simuliert, wie sich die Aufmerksamkeitsverteilung und die Blickfrequenz über längere Zeiträume verhalten. In Abbildung 3.6




Abbildung 3.6 – Unterschiedlicher Operationalisierungen der Erwartung. Vergeht zwischen zwei Ereignissen eine typische Zeitspanne, dann ist die Wiederauswahl von g_2 zum Zeitpunkt t_3 oftmals nicht sinnvoll, da das letzte Ereignis kurz davor aufgetreten ist (t_2). Die 1. Operationalisierungsvariante über die Ereignisrate (blau) berücksichtigt dies nicht, die 2. Variante mit Ereignisfunktionen (grün) dagegen schon.

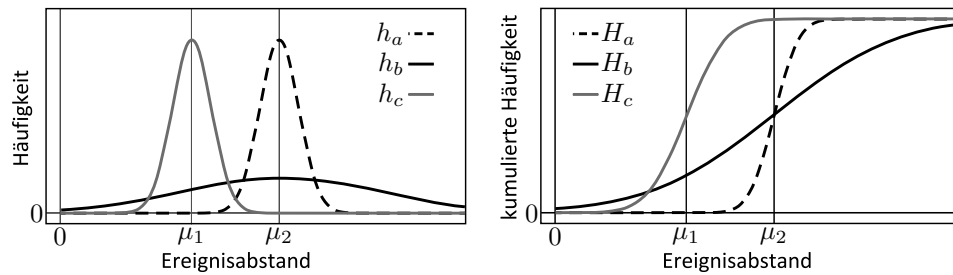


Abbildung 3.7 – Veranschaulichung des Effekts, den verschiedene Ereignisabstandsverteilungen auf die kumulierten Häufigkeitsverteilungen haben.

ist die Problematik dieses Vorgehens bei der Betrachtung kürzerer Zeiträume dargestellt. Die Abbildung zeigt einen potentiellen Simulationslauf eines kognitiven Agenten mit dem aktuellen visuellen Fokus und dem aktuell ausgewähltem Ziel. Wenn Ereignisse für das Ziel g_2 in typischen Abständen auftreten, die größer sind als der dargestellte Zeitabschnitt, dann macht es für den Beobachter zwar Sinn zum Zeitpunkt t_1 das Ziel g_2 auszuwählen, jedoch weniger zum Zeitpunkt t_3 . Kurz vorher (t_2) wurde bereits ein Ereignis für g_2 registriert, so dass der Beobachter typischerweise kein neues Ereignis für g_2 in so kurzer Zeit erwarten wird.

Bei der 1. Operationalisierungsvariante der Erwartung über die Ereignisraten wird dieser Aspekt nicht berücksichtigt. Diese Variante ist als blaue Kurve in der Abbildung eingetragen. Der Wert des Erwartungsparameter u_{g_2} ist zu den beiden Zeitpunkten t_1 und t_3 , an denen eine Zielauswahl stattfindet, annähernd identisch. Dies ist bei der 2. Variante anders, die die Ereignisfunktionen zur Operationalisierung verwendet. Sie ist als grüne Funktion in der Abbildung dargestellt. Der Erwartungsparameter für g_2 ist nun zum Zeitpunkt t_3 deutlich geringer als zum Zeitpunkt t_1 . Für das AIE-Modell wird daher die zweite Operationalisierungsvariante verwendet. Zur Veranschaulichung sind in Abbildung 3.7 verschiedene Ereignisabstandsverteilungen (links) sowie deren **kumulierte Verteilungsfunktionen** (rechts) abgebildet. Die Abbildung demonstriert, wie unterschiedliche Ereignismuster die Erwartung beeinflussen. Bei kurzen Ereignisabständen (h_c) steigt die Erwartung früher wieder an, als bei langen Ereignisabständen (h_a). Bei einer großen Streuung der Abstände (h_b) steigt die Erwartung ebenfalls früher, dafür jedoch langsamer an.

3.4 Lernphase

Zu Beginn der Simulation sind keine **Ereignisfunktion** für die einzelnen Ziele vorhanden, da noch keine **Ereignisse** aufgetreten sind. Die Auswahlwahrscheinlichkeit der einzelnen Ziele wird zu Beginn daher vor allem durch die Wertparameter der Ziele vorgegeben. Mit voranschreitender Simulation wächst die Anzahl registrierter Ereignisse und es bilden sich detaillierte Ereignisfunktionen aus. Die Ereignisfunktionen verändern sich also dynamisch insbesondere zu Beginn der Simulation. In Abbildung 3.8 ist die Entwicklung einer Ereignisfunktion über die Zeit beispielhaft dargestellt. Die Ereignisfunktion stammt aus der Simulation des Fahrermodells, das in Abschnitt 5.6 vorgestellt wird. In der Grafik bezeichnet u_g^t die Ereignisfunktion für das Ziel g nach t Zeiteinheiten. Nach fünf Minuten (u_g^{5min}) sind nur wenige Ereignisse in die Ereignisfunktion eingeflossen. Daher sind die Funktionssprünge

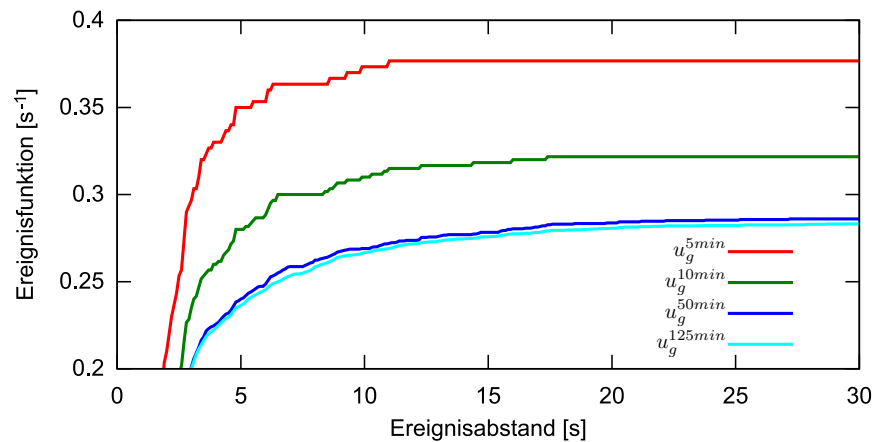


Abbildung 3.8 – Ausschnitt einer Ereignisfunktion zu vier verschiedenen Zeitpunkten einer 125-minütigen Simulation. Die Funktion gehört zum Ziel `lateral_control` des Fahrermodells, das in Abschnitt 5.6 vorgestellt wird (`g=lateral_control`).

deutlich sichtbar. Zudem unterscheidet sich der Funktionsverlauf noch stark von der Ereignisfunktion, die sich nach zehn Minuten ergibt. Nach 50 Minuten Simulation ist die Funktion beinahe identisch mit derjenigen, die sich nach 125 Minuten Simulation zeigt. Dies demonstriert, dass die Ereignisfunktion erst über einen gewissen Zeitraum erlernt werden muss.

Um das AIE-Modell anzuwenden und Vorhersagen zum Aufmerksamkeitsverhalten zu machen, sollte daher vorab eine Lernphase abgeschlossen sein, in der das Modell simuliert wird, bis sich stabile Ereignisfunktionen gebildet haben.

Bezüglich des Lernverhaltens des AIE-Modells sind einige Aspekte von Interesse:

1) Konvergenz der Ereignisfunktionen gegen eine Grenzfunktion

In Abbildung 3.8 lässt sich erahnen, dass sich der Verlauf der Ereignisfunktion nach einer gewissen Simulationszeit kaum noch ändert. Die Vermutung liegt nahe, dass die Ereignisfunktion in diesem Fall gegen eine Grenzfunktion konvergiert. Dies sollte untersucht werden. Allerdings kann diese Untersuchung nicht allgemeingültig durchgeführt werden, da die Ereignishäufigkeit von den simulierten Szenarien abhängt, in denen das AIE-Modell verwendet wird.

2) Konvergenzgeschwindigkeit

Wenn man von einer stabilen Grenzfunktion ausgeht, stellt sich die Frage, wie schnell diese erreicht wird und welche Faktoren die Geschwindigkeit beeinflussen. Eng hiermit verwandt ist auch der nächste Aspekt.

3) Dauer der Lernphase

Da die Aufmerksamkeit die eigentliche Zielgröße darstellt, ist in diesem Zusammenhang vor allem interessant, wie ähnlich sich Ereignisfunktionen sein müssen, damit der Effekt auf die Simulation der Aufmerksamkeitsverteilung vernachlässigt werden kann.

Für Häufigkeitsverteilungen von unabhängigen und identisch verteilten Zufallsvariablen ist das Konvergenzverhalten bekannt (van der Vaart, 2000). Allerdings sind Rückkopplungen beim Lernen der Ereignisfunktionen vorhanden. Dies ist in Abbildung 3.9 zu sehen. Die Ereignisfunktionen beeinflussen die Auswahl der Ziele. Die




Abbildung 3.9 – Rückkopplung beim Lernen der Ereignisfunktionen

visuelle Aufmerksamkeit richtet sich wiederum auf die vom ausgewählten Ziel benötigten Informationen. Ereignisse fließen schließlich nur in die Ereignisfunktionen ein, wenn sie auch wahrgenommen wurden. Beinhaltet die Aufgabe des Beobachters nicht nur das Beobachten des Systems, sondern auch aktive Interaktion, dann beeinflusst die Zielauswahl nicht nur die visuelle Aufmerksamkeit, sondern auch die Interaktion mit dem beobachteten System. Dies wiederum kann das Auftreten von Ereignissen beeinflussen.

Durch diese Rückkopplung sind die Ereignisabstände, die der kognitive Agent beobachtet, weder unabhängig noch über die Zeit identisch verteilt. Um zu untersuchen, wie stark der Einfluss dieser Rückkopplung ist und um eine Vermutung über eine mögliche Lerngeschwindigkeit zu erhalten, wird hier die theoretische Konvergenzgeschwindigkeit der Ereignisfunktionen bestimmt, wenn keine Rückkopplung vorhanden ist. Nach dem Gesetz der großen Zahlen konvergiert die Ereignisabstandsverteilung $H_g(t)$ des Ziels g , die die während der Simulation beobachtete empirische Verteilungsfunktion darstellt, bei unabhängigen und identisch verteilten Ereignisabständen für $n \rightarrow \infty$ fast sicher sowohl **punktweise** als auch **gleichmäßig** gegen die tatsächliche Ereignisabstandsfunktion (van der Vaart, 2000, S.265 f.). Die Konvergenzrate beträgt in dem Fall für jeden Punkt der Ereignisabstandsverteilung $n^{-\frac{1}{2}}$ (van der Vaart, 2000, S.265). Dabei bezeichnet $n = |E_g|$ die Anzahl der beobachteten Ereignisse, die in H_g einfließen. Für die Simulation mit dem AIE-Modell ist jedoch die Dauer d_g , die für die Simulation von g benötigt wird, interessanter als die absolute Anzahl an Ereignissen. Unter Verwendung der durchschnittlichen Ereignisrate (Gleichung 3.4, S. 73) lässt sich die Konvergenzgeschwindigkeit in Abhängigkeit von der Zeitdauer formulieren als:

$$\sqrt{r_g} \cdot d_g^{-\frac{1}{2}} \quad (3.11)$$

Wenn der Effekt der Rückkopplung gering ist, dann sollte zumindest der grundsätzliche Kurvenverlauf erhalten bleiben. Im Falle einer Konvergenz wird daher eine Geschwindigkeit erwartet in der Art:

$$a \cdot d_g^{-b} \quad \text{mit} \quad b \approx \frac{1}{2} \quad (3.12)$$

An dieser Stelle sind weder das zu beobachtende System noch das simulierte Szenario oder die Aufgabenbeschreibung und -verarbeitung bekannt. Daher lässt sich keine allgemeine Stabilitätsanalyse durchführen. Das Lernverhalten des AIE-Modells wird infolgedessen anhand der beiden Evaluationsszenarien untersucht.

Eine wünschenswerte Eigenschaft des simulierten Szenarios ist, dass sich zumindest die Wahrscheinlichkeitsverteilung der Ereignisursachen während der Simulation nicht ändert. Wenn beispielsweise das Wahrnehmen eines Signallämpchens ein Ereignis für den simulierten Benutzer darstellt, dann sollte sich die Wahrscheinlichkeit, mit der das Lämpchen aufleuchtet, während der Simulation nicht ändern.

Annahme 1:

Die Wahrscheinlichkeitsverteilung der Ereignisursachen ändert sich nicht.

Andernfalls werden sich voraussichtlich auch die Ereignisabstände in den Ereignisfunktionen ändern. Mit voranschreitender Simulation wird sich die Ereignisfunktion zwar an die veränderte Wahrscheinlichkeitsverteilung anpassen können, dennoch benötigt dies eine weitere Lernphase. Im Kontext dieser Arbeit wird immer davon ausgegangen, dass die Wahrscheinlichkeitsverteilung der Ereignisursachen innerhalb eines simulierten Szenarios nicht verändert wird.

In den Abschnitten 4.3.4 und 5.8.2.3 wird anhand der Anwendungsbeispiele untersucht, ob in diesen Szenarien eine Konvergenz der Ereignisfunktionen festgestellt werden kann und ob die Konvergenzgeschwindigkeit derjenigen in Gleichung 3.12 ähnelt. Zudem wird die Veränderung des Blickverhaltens während der Lernphase beleuchtet.

3.5 Initialisierung

Ein wichtiger Aspekt der Lernphase ist die Initialisierung der **Ereignisfunktion**. Da nichts über die Ereignisverteilungen bekannt ist, bietet es sich an, mit leeren Häufigkeitsverteilungen zu beginnen:

$$\begin{aligned} h_g^0(\Delta t) &= 0 \\ \Rightarrow H_g^0(\Delta t) &= 0 \end{aligned}$$

Durch diese Initialisierung wird es insbesondere zu Beginn der Simulation vorkommen, dass bei der Zielauswahl die Ereignisfunktionen aller Ziele den Wert null haben. Für diesen Fall wird der Erwartungsterm in Gleichung 3.1 definiert als $\frac{u_g}{\sum_{g_j \in G} u_{g_j}} = 0$, so dass sich die Aufmerksamkeitsverteilung lediglich nach den Wertparametern v richtet.

Dieses Vorgehen ist bei der multiplikativen Formulierung der SEEV-Formel nicht möglich. Ist der Erwartungsparameter eines Ziels g gleich null, so ist auch dessen Aufmerksamkeitsgewicht null und damit auch die Auswahlwahrscheinlichkeit von g . Da das Ziel nicht ausgewählt wird, wird auch der Fokus nicht auf die für g relevanten Informationsquellen gerichtet. Dies ist aber nötig, damit **Ereignisse** für das Ziel beobachtet werden können. Ohne wahrgenommene Ereignisse bleibt die Ereignisfunktion jedoch für immer unverändert.

Dieses Problem wird mit einer anderen Initialisierung der Verteilungen umgangen, indem für jedes Ziel mindestens ein künstliches Ereignis für $\Delta t = 0$ erzeugt wird:

$$\begin{aligned} h_g^0(\Delta t) &= \begin{cases} 1 & \text{für } \Delta t = 0 \\ 0 & \text{für } \Delta t > 0 \end{cases} \\ \Rightarrow H_g^0(\Delta t) &= 1 \end{aligned}$$

Auf diese Weise ist die Wahrscheinlichkeit, dass ein Ziel ausgewählt wird, nie null. Mit voranschreitender Simulation und damit auch wachsender Anzahl an beobachteten Ereignissen wird der Einfluss des künstlichen Ereignisses auf die Ereignisfunktion monoton abnehmen. Daher sollte der verfälschende Effekt dieses Ereignisses am Ende der Trainingsphase vernachlässigbar sein.

3.6 Diskussion

In diesem Kapitel wurde ein Simulationsmodell der Aufmerksamkeitsverteilung vorgestellt, das die Aufmerksamkeit in Abhängigkeit der Erwartung von **Ereignissen**

und des Informationswertes steuert. Dies sind zwar zwei wichtige Aspekte der Aufmerksamkeit, jedoch sind es bei weitem nicht die einzigen, die eine Rolle für die Aufmerksamkeitsverteilung spielen. Es werden nun einige weitere Aspekte adressiert, die für die Simulation der Aufmerksamkeit von Relevanz sind, die aber bei den bisherigen Ausführungen nicht berücksichtigt wurden, um die Beschreibung einfach zu halten. Anschließend werden die Anforderungen diskutiert, die eine kognitive Architektur für die Integration des AIE-Modells erfüllen muss. Darauf aufbauend wird in Abschnitt 3.7 schließlich die beispielhafte Realisierung des AIE-Modells in einer kognitiven Architektur demonstriert.

3.6.1 Erfahrung mit der Aufgabe

Wickens bezeichnet die Erwartung und den Informationswert als wissensgetriebene Einflussfaktoren für die Aufmerksamkeitsverteilung (Wickens und McCarley, 2008, S.50). Bezüglich der Erwartung ist damit das Wissen über die Ereignisrate oder die Bandbreite gemeint. Der Aufwand, den der Überwacher benötigt, um das Wissen zu erlangen, ist bei den beiden Konzepten unterschiedlich. Die Bandbreite eines sich kontinuierlich verändernden Informationswertes kann typischerweise schnell wahrgenommen werden, indem die Dynamik der Variablen in einer Informationsquelle beobachtet wird (Miller et al., 2004). Dies kann zum Beispiel die Geschwindigkeit sein, mit der sich der Zeiger eines analogen Instruments bewegt oder die Geschwindigkeit, mit der sich der Abstand zu einem vorausfahrenden Fahrzeug ändert. Um Wissen über die Ereignisrate zu erlangen, ist dagegen Erfahrung mit der Aufgabe nötig, da der Überwacher erst eine Reihe von Ereignissen beobachten muss, bevor er ein Gespür für die Ereignishäufigkeit erlangen kann. Für den Überwacher ist die Ereignishäufigkeit die ausschlaggebende Information, da sie das eigentliche Kriterium für die Aufgabebearbeitung darstellt. Die Bandbreite kann jedoch als Heuristik verwendet werden, wenn nichts über die tatsächliche Ereignisrate bekannt ist (Miller et al., 2004).

Miller et al. (Miller et al., 2004; Miller und Fu, 2007) zeigten, dass sowohl Wissen über die Bandbreite als direkt wahrnehmbare Information (proximal cue) als auch über die mit Erfahrung gelernte Ereignisrate (distal cue) verwendet wird, um die Aufmerksamkeitsverteilung der aktuellen Situation anzupassen. Der Einfluss der Ereignisrate wird mit zunehmender Erfahrung jedoch immer ausschlaggebender. Da das AIE-Modell die Erwartung über die Ereignishäufigkeit operationalisiert und nicht über die Informationsbandbreite, ist es tendenziell besser geeignet, um Nutzer zu modellieren, die bereits Erfahrung mit der betreffenden Aufgabe haben. Es wird daher davon ausgegangen, dass das AIE-Modell zur Modellierung von erfahrenen Benutzern verwendet wird.

Annahme 2:
Das AIE-Modell wird zur Modellierung von erfahrenen Nutzern verwendet.

3.6.2 Kognitiver Aufwand

Bei der Simulation von kognitiven Modellen stellt sich typischerweise die Frage, wie viel Zeit die modellierten Prozesse in Anspruch nehmen bzw. wieviel Aufwand sie vom Menschen erfordern. Dieser Aspekt wird im AIE-Modell nicht berücksichtigt. Es wird stattdessen davon ausgegangen, dass das Erlernen und Nutzen der Ereignishäufigkeiten keine zusätzliche Zeit in Anspruch nimmt. Studien zu diesem Thema legen nahe, dass ein etwaiger Aufwand vernachlässigt werden kann: So argumentieren Zacks und Hasher (2002), dass das Ablegen von Informationen zu Häufigkeiten im Gedächtnis keinen Aufwand erfordert. Es geschieht automatisch und unbeabsichtigt. Für das Nutzen von Häufigkeitsinformationen wiederum gibt

Annahme 3:
Das Erlernen und Nutzen von Ereignishäufigkeiten erfordert keinen zusätzlichen Aufwand.

Brown (2002) eine Taxonomie zu möglichen Strategien an. Für die Aufmerksamkeitsverteilung ist die exakte Ereignisrate typischerweise nicht relevant, sondern viel eher der subjektive Eindruck der Häufigkeit. Nach Brown (2002) entspricht das Nutzen solcher Häufigkeitsinformationen einer nicht-aufzählenden und nicht-numerischen Strategie. Sie ist dadurch gekennzeichnet, dass die Häufigkeitsinformation beinahe unmittelbar zur Verfügung steht. Dies spricht dafür, dass auch der Aufwand für das Abrufen der Häufigkeitsinformation vernachlässigbar ist.

3.6.3 Eingeschränktes Aufgabenschema

Bei den bisherigen Überlegungen ist das AIE-Modell von einem bestimmten Aufgabenschema ausgegangen (vgl. Abbildung 3.3, S. 68), das jedoch einige einschränkende Annahmen macht und sich nicht auf alle Situationen anwenden lässt. Diese Annahmen werden hier kurz diskutiert und zum Teil gelockert.

3.6.3.1 Relevanz der Informationsquellen

Bisher wurde nur der Fall betrachtet, dass für jede Aufgabe genau eine Informationsquelle relevant ist. Es können aber Situationen auftreten, in denen mehrere Informationsquellen Informationen für dieselbe Aufgabe liefern. Dies ist typischerweise der Fall, wenn dieselbe Information in unterschiedlichen Informationsquellen angezeigt wird. Zum Beispiel wird die Fahrzeuggeschwindigkeit häufig sowohl auf der Instrumentenleiste hinter dem Lenkrad als auch auf dem Navigationsgerät dargestellt.

Umgekehrt kann eine Informationsquelle auch für mehrere Aufgaben relevante Informationen liefern. So stellt das Navigationsgerät sowohl Positionsinformationen für die Navigation zur Verfügung als auch die aktuelle Geschwindigkeit, die für das Halten der Wunschgeschwindigkeit relevant ist.

Wickens et al. (2003a) integrierten daher eine Relevanzkomponente R in das SEEV-Modell. Dies wurde in Abschnitt 2.1.4.4 anhand der Expected-Value-Variante des SEEV-Modells beschrieben (s. Gleichung 2.6, S. 28). Diese Gleichung wird hier erneut wiedergegeben. Sie berechnet das Aufmerksamkeitsgewicht einer Informationsquelle A durch (vgl. Wickens et al., 2003a, S.373):

$$w(A) = BW_A \cdot \sum_{g \in G} (R_{A,g} \cdot V_g) \quad (3.13)$$

Ähnlich wie beim AIE-Modell betrachteten Wickens et al. bei ihren Untersuchungen die Bottom-Up-Faktoren nicht. Es ist zu beachten, dass mit obiger Formel das Aufmerksamkeitsgewicht einer Informationsquelle berechnet wird und damit die visuelle Aufmerksamkeitsverteilung bestimmt wird. Die ermittelten Werte lassen sich gut experimentell mit Blickdaten überprüfen. Das AIE-Modell beschreibt dagegen die mentale Aufmerksamkeit auf eine Aufgabe. Diese lässt sich aber ähnlich angeben, indem nicht die Summe über alle Aufgaben, sondern über alle Informationsquellen gebildet wird.

Wie in Gleichung 3.1 (S. 69) zu sehen ist, beinhaltet das AIE-Modell keine Relevanzkomponente. Vielmehr geht es davon aus, dass die Relevanz bereits in der Aufgabenbeschreibung abgebildet ist. Eine Informationsquelle ist relevant für eine Aufgabe, wenn in der Aufgabenbeschreibung beschrieben ist, wie die Information aus der Informationsquelle für die Bearbeitung der Aufgabe verwendet wird.

Wenn in der Beschreibung einer Aufgabe mehrere Informationsquellen angegeben sind, dann betrachtet das AIE-Modell die Ereignisse, die für die Aufgabe auftreten,

auch gemeinsam für alle Informationsquellen. Umgekehrt werden Ereignisse, die von einer Informationsquelle herrühren, die für mehrere Aufgaben relevant ist, auch für alle Aufgaben gewertet. Dies folgt aus der Definition der Ereignisse, die ein Ereignis als das Nutzen von Informationen zur Bearbeitung einer Aufgabe definiert. Wird dieselbe Information von zwei Aufgaben genutzt, so wird dies jeweils als ein Ereignis für beide Aufgaben gewertet.

3.6.3.2 Feste Aufgabensequenzen und alternative Bearbeitungen

In Abschnitt 3.1 (S. 63) wurde erläutert, dass das AIE-Modell zur Simulation mehrerer Aufgaben dient, die in freier Sequenz ausgeführt werden. Es lässt sich jedoch auch für komplexere Aufgabenstrukturen verwenden, die zusätzlich alternative und feste Aufgabensequenzen enthalten. Bei festen Aufgabensequenzen muss lediglich sichergestellt werden, dass immer nur das erste noch nicht erreichte Aufgabenziel der Sequenz in der Menge G (s. Gleichung 3.1, S. 69) der auswählbaren Ziele enthalten ist. Sobald das Ziel erreicht wurde, wird es aus G entfernt und durch das darauffolgende Aufgabenziel ersetzt. Auf diese Weise bleibt die Reihenfolge der Sequenz erhalten. Bei alternativen Aufgabensequenzen muss dagegen sichergestellt werden, dass von den Aufgabenzielen immer genau eine der Alternativen zu G hinzugefügt wird.

3.6.3.3 Visuelle Suche

Eine weitere Art von Aufgaben, die häufig auftritt, aber durch das bisher betrachtete Aufgabenschema nicht darstellbar ist, ist die visuelle Suche. Sie ist dadurch charakterisiert, dass in einer Szenerie eine Information gesucht wird, deren genauer Ort nicht bekannt ist. Auch hier spielt es eine essenzielle Rolle, wohin die visuelle Aufmerksamkeit gerichtet wird. Dem AIE-Modell liegt die Annahme zugrunde, Das AIE-Modell geht davon aus, dass der Ort der Information bekannt ist und der Blick immer direkt zu diesem Ort bewegt wird, wenn die Information benötigt wird. Bei der visuellen Suche ist dies nicht der Fall. Für diese Aufgaben ist das AIE-Modell daher nicht geeignet, zumal bei der visuellen Suche Bottom-Up-Faktoren, wie die Auffälligkeit der Informationen, eine wichtigere Rolle spielen. Diese werden vom AIE-Modell jedoch nicht berücksichtigt. Zur Simulation der Aufmerksamkeit bei visuellen Suchaufgaben sollten daher darauf spezialisierte Modelle verwendet werden, wie sie sich zum Beispiel bei Wolfe (2007) oder Koch und Ullmann (1985) finden.

<p>Annahme 4: Das AIE-Modell besitzt nur Gültigkeit in Zusammenhang mit der Simulation einer Aufgabenbeschreibung ohne externe Störungen und ohne Notwendigkeit zur visuellen Suche.</p>

3.6.4 Blickdauer und Blickfrequenz

Das SEEV-Modell beschreibt, welche Faktoren Einfluss auf die visuelle Aufmerksamkeitsverteilung haben. Dabei geht es nicht auf die Eigenschaften einzelner Blickfixationen ein, sondern gibt lediglich eine aggregierte Abschätzung zur prozentualen Blickverteilung. Das AIE-Modell übernimmt die grundsätzliche Idee des SEEV-Modells und überführt es in ein Simulationsmodell, das in der Lage ist, konkrete Blicksequenzen zu erzeugen. Bei der Erzeugung von Blicksequenzen unterscheidet Moray (1986, S. 40(22)) zwei Mechanismen: Den Mechanismus, der entscheidet, wann eine Informationsquelle betrachtet wird, bezeichnet er als Ablaufplanungsalgorithmus. Als Datenakquisealgorithmus bezeichnet er dagegen den Mechanismus, der entscheidet, wie lange der Blick auf einer Informationsquelle ruht. Die bei einigen Blickdatenanalysen zugrunde gelegte Immediacy-Annahme (Just und Carpenter, 1980) geht davon aus, dass die Blickdauer vor allem durch die Zeit bestimmt

Annahme 5:
Kognitive Architekturen, die das AIE-Modell verwenden, implementieren einen Datenakquisitionsalgorithmus.

wird, die der Mensch zur Verarbeitung der Informationen benötigt. Das beinhaltet nicht nur die Wahrnehmung der physikalischen Erscheinung der Information und das Kodieren dieser, sondern auch das semantische Verständnis der Information. Alle diese Aspekte sind relevant für den Datenakquisitionsalgorithmus. Auf den Datenakquisitionsalgorithmus geht das AIE-Modell jedoch nicht ein, sondern betrachtet nur die Erzeugung der Blicksequenz und geht davon aus, dass die benötigte Zeit für die Datenakquisition bekannt ist. Da es vorgesehen ist, das AIE-Modell in eine kognitive Architektur zu integrieren, sollte der Datenakquisitionsalgorithmus durch die jeweilige Architektur bereitgestellt werden. In Abschnitt 3.7 wird dies am Beispiel von CASCaS beschrieben.

3.6.5 Zentrale Annahmen des AIE-Modells

Wie bereits erwähnt, kann das AIE-Modell nur in Zusammenhang mit der Simulation einer Aufgabenbeschreibung verwendet werden. Typischerweise ermöglichen kognitive Architekturen eben solche Simulationen.

Die Integration in eine kognitive Architektur führt jedoch auch zu einigen Problemen. Es erschwert insbesondere die Validierung des Modells, da Modellvorhersagen immer nur im Zusammenhang mit der kognitiven Architektur und der jeweiligen Aufgabenprozedur erzeugt werden. Bei einem Agenten, der in einer kognitiven Architektur simuliert wird, ist also nicht direkt sichtbar, ob die beobachteten Verhaltenseffekte durch die Architektur oder das AIE-Modell hervorgerufen werden. Dies ist ein grundsätzliches Problem, das sich bei der Entwicklung von kognitiven Architekturen zeigt.

Bei der Entwicklung der kognitiven Theorien, die durch die Architektur implementiert sind, wird häufig vorgeschlagen, dem Ansatz von Lakatos (1970) zu folgen ((Newell, 1990, S.14); (Taatgen, 1999, S.31); (Cooper, 2007); (Lane und Gobet, 2012)).

Lakatos schlägt vor, eine Theorie in einen harten Kern und periphere Hypothesen zu unterteilen. Empirische Ergebnisse, die gegen die Theorie sprechen, führen nicht direkt dazu, dass die Theorie als Ganzes verworfen wird. Eine Theorie wird erst verworfen, wenn eine neue Theorie gefunden wurde, die die bisherigen Ergebnisse erklärt und neue Vorhersagen liefern kann. Eine solche Theorie sollte auf der vorherigen basieren, wobei lediglich Änderungen in den peripheren Hypothesen vorgenommen wurden.

Für die Integration in eine kognitive Architektur macht das AIE-Modell einige Annahmen, die sich je nach Architektur sowohl dem harten Kern der zugrunde liegenden kognitiven Theorie, als auch peripheren Annahmen zuordnen lassen. Diese Annahmen betreffen folgende Punkte:

Annahme 6:
Das Verhalten von Menschen ist zielorientiert.

Zielorientiertes Handeln. Eine Annahme, die dem AIE-Modell zugrunde liegt, ist die, dass das Verhalten von Menschen zielorientiert ist, denn schließlich ist die Zielauswahl der Prozess, der durch das AIE-Modell beeinflusst wird. Für die Annahme des zielorientierten Handelns existiert ein breiter Konsens. Sie kann häufig als Teil des harten Kerns der Theorien angesehen werden. Das Konzept von Zielen findet sich in einer breiten Palette von kognitiven Architekturen wie auch in den bereits angesprochenen Beispielen ACT-R (Anderson, 2009), EPIC (Kieras, 2007), Soar (Laird, 2012) oder CASCaS (Lüdtke et al., 2009).

Identifikation von Ereignissen. In der Architektur müssen sich Ereignisse identifizieren lassen, da über diese die Erwartung operationalisiert wird. Dieses

Konzept lässt sich nicht so offensichtlich in bestehenden Architekturen erkennen. Die in diesem Kapitel gegebene Definition eines Ereignisses spricht von Ereignissen, wenn Informationen zum Erreichen eines Ziels genutzt werden. Die Verarbeitung von Informationen ist eine typische Charakteristik von kognitiven Architekturen, da allen der Zyklus aus Perzeption – Kognition – Aktion zugrunde liegt. Laird (2012, S.11f.) zeichnet ein prototypisches Bild, das viele aktuelle kognitive Architekturen gemeinsam teilen. Dies beinhaltet die Auswahl von Aktionen basierend auf Informationen aus dem Langzeit- und Kurzzeitgedächtnis. Als Formalismus werden hierfür häufig Produktionsregeln verwendet. Das ist auch in den oben genannten Architekturen der Fall. In Abschnitt 3.7 wird am Beispiel von CASCAS demonstriert, wie sich über die Produktionsregeln Ereignisse formal definieren lassen.

Annahme 7:

In einer Architektur, die das AIE-Modell integriert, lassen sich Ereignisse, als das Nutzen von Informationen zum Erreichen eines Zieles, klar identifizieren.

Datenakquisealgorithmus. In Experimenten wird der Fokus der Aufmerksamkeit normalerweise über Blickmessungen bestimmt. Zur Evaluierung benötigt das AIE-Modell daher ein Modell zur Bestimmung der Fixations- und Sakkadendauern. Es übernimmt die Funktion des von Moray (1986) angesprochenen Datenakquisealgorithmus. Viele Architekturen enthalten ein solches Modell in unterschiedlichen Ausprägungen. Allerdings werden diese Modelle oftmals nicht dem harten Kern der zugrunde liegenden Theorie zugerechnet. So wurden entsprechende Modelle in ACT-R und Soar auch erst mit zeitlicher Verzögerung integriert. Da die Fixationsdauer aber das Blickverhalten erheblich beeinflusst, kann sie bei der Evaluierung des AIE-Modells nicht außer Acht gelassen werden. Dies gilt insbesondere, wenn es darum geht, die Ursache einer etwaigen Abweichung der Vorhersagen zu experimentellen Ergebnissen zu suchen. In Kapitel 4 wird diese Problematik deutlicher werden.

s. Annahme 5:

Kognitive Architekturen, die das AIE-Modell verwenden, implementieren einen Datenakquisealgorithmus.

Diese Annahmen müssen von einer kognitiven Architektur erfüllt sein, damit sich das AIE-Modell integrieren lässt.

3.7 Integration in CASCAS

Für die Anwendung des AIE-Modells wird eine ausführbare Aufgabenbeschreibung benötigt, die in Interaktion mit einer Umgebungssimulation ausgeführt wird. Kognitive Architekturen sind hierfür gut geeignet, da sie typischerweise eine einfache Interaktion mit künstlichen oder realen Umgebungen erlauben und Formalismen zur Beschreibung von Aufgaben vorgeben.

Um das AIE-Modell zu evaluieren, wird es beispielhaft in die kognitive Architektur CASCAS integriert, die in Abschnitt 2.3 beschrieben ist. In diesem Abschnitt wird beschrieben, wie das AIE-Modell in CASCAS integriert wurde, und auf welche Weise es mit den bereits vorhandenen Modellen von CASCAS interagiert.

Zur Integration des AIE-Modells müssen vor allem zwei Schritte durchgeführt werden: Zum einen müssen die in Kapitel 3 beschriebenen Wert- und Erwartungsparameter für jedes Ziel bestimmt werden. Das bedeutet, die Ziele müssen sich mit dem statischen Wertparameter annotieren lassen und die Ereignisse müssen während der Simulation aufgezeichnet werden, um den Erwartungsparameter dynamisch bestimmen zu können. Zum anderen muss die Möglichkeit geschaffen werden, die Zielauswahl basierend auf diesen beiden Parametern zu beeinflussen.

3.7.1 Statische Parameterangabe

Der Wertparameter eines Ziels g ändert sich während der Simulation nicht. Er muss daher nur einmalig angegeben werden. Hierfür wurde das **Goal**-Kommando erweitert, mit dem sich neue Aufgabenziele auf die Zielagenda setzen lassen (s. Abschnitt 2.3.4 und D.3). Beim Hinzufügen eines Ziels zur Zielagenda kann nun der Wertparameter (v_g) als ein weiterer optionaler Parameter über das Schlüsselwort **value** angegeben werden. Der Wertebereich von v_g ist festgelegt auf positive, reelle Zahlen. Der Effekt auf die Simulation des Agenten ergibt sich immer nur in Relation zu den Wertparametern der anderen Ziele. Da es sich um eine relative Größe handelt, hat v_g für sich genommen keine große Aussagekraft. Er hat zudem keine festgelegte Einheit. Bei Verwendung des **Lowest-Ordinal-Algorithmus** ist er tatsächlich einheitenlos. Allerdings kann er sich auch auf reale Größen, wie monetäre Kosten oder ähnliches beziehen.

Der Erwartungsparameter (u_g) des AIE-Modells kann sich im Gegensatz zum Wertparameter dynamisch ändern. Er wird zudem automatisch aus der Simulation abgeleitet und muss daher nicht statisch beim Hinzufügen eines Ziels zur Zielagenda festgelegt werden. Dennoch wurde die Option geschaffen, den Erwartungsparameter analog zum Wertparameter über einen optionalen Parameter (**expectancy**) fest vorzugeben. Auf diese Weise lassen sich verschiedene alternative Umsetzungen eines Aufmerksamkeitsmodells vergleichen. Die Variante mit statischen Parametervorgaben ähnelt stark dem Vorgehen in der aktuellen Version von MIDAS (Gore et al., 2009). Dort wird der Erwartungswert vorab durch eine Experteneinschätzung der **Ereignisraten** definiert.

Ebenso wie der Wertparameter, hat auch dieser Parameter keine feste Einheit und kann über den **Lowest-Ordinal-Algorithmus** bestimmt werden oder sich nach realen Größen wie der Ereignisrate richten. Bei Nichtangabe wird der Erwartungsparameter dynamisch anhand der wahrgenommenen **Ereignisse** bestimmt, so wie es im AIE-Modell vorgesehen ist.

Die **RHS**-Aktion zum Hinzufügen eines neuen Ziels g zur Zielagenda kann daher nun wie folgt aussehen:

```
Goal, name=g, mode=persistent, value=v_g, expectancy=u_g
```

3.7.2 Ereignisse

Ein **Ereignis** ist über das Nutzen von Informationen zur Erreichung eines Ziels definiert. Ein in CASCaS instantiiertes Agent nutzt Informationen zur Erreichung eines Ziels, wenn er eine für dieses Ziel passende reguläre Regel feuert. Dies wird




Abbildung 3.10 – Typisches Schema für die Aufgabenbearbeitung in CASCaS. Wahrgenommene Informationen werden für die Erreichung eines Ziels g von einem CASCaS-Agenten genutzt, indem eine passende reguläre Regel gefeuert wird. Das Feuern einer solchen Produktionsregel wird daher mit einem Ereignis assoziiert.

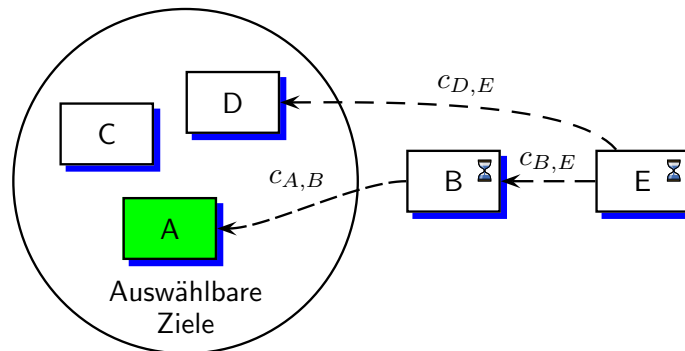


Abbildung 3.11 – Neue Struktur der Zielagenda mit fünf Zielen (vgl. alte Struktur in Abbildung 2.10). Ziele werden als Menge verwaltet. Die Ordnung durch die Vorbedingungen der wartenden Ziele besteht weiterhin.

in Abbildung 3.10 noch einmal verdeutlicht. Es zeigt das bereits aus Abbildung 3.4 (S. 73) bekannte generelle Taskschema. Allerdings sind hier die Zustandsübergänge mit den Regeltypen von CASCAS beschriftet. Es zeigt auf, welcher Regeltyp von CASCAS welchen Zustandsübergang verursacht.

Da erst durch reguläre Regeln Aktionen zur Erreichung eines Ziels ausgeführt werden, wird das Feuern einer regulären Regel in CASCAS als Ereignis aufgefasst. Jede reguläre Regel ist einem Ziel zugeordnet. Somit lassen sich die Ereignisse für jedes Ziel separat aufzeichnen. Aus diesen Aufzeichnungen werden zur Laufzeit die [Ereignisfunktion](#) gebildet.

Da erst eine gewisse Anzahl an Ereignissen aufgetreten sein muss, bevor eine Ereignisfunktion stabil ist und sich die Ereignisfunktion mit fortlaufender Simulation immer weniger ändert, muss ein mit CASCAS erstellter Agent zuerst in einer Lernphase einige Zeit simuliert werden, damit sich die Ereignisfunktionen stabilisieren. Diese lassen sich nach der Lernphase abspeichern und bei späteren Simulationen wieder einladen. Hierzu wird eine entsprechende Option in der [Agentenkonfigurationsdatei](#) angeboten.

Um einen effizienten Zugriff auf die Ereignisfunktionen zu erreichen, werden die Ereignisabstände nicht exakt gespeichert, sondern in Schritten von 100 Millisekunden diskretisiert. Die Schrittweite kann über den Parameter (`event_distance_discretization`) vor der Simulation in der [Agentenkonfigurationsdatei](#) geändert werden.

3.7.3 Auswahl der Ziele

Um die Zielauswahl auf Basis der [Ereignisfunktion](#) zu ermöglichen, wurde die Struktur der Zielagenda verändert. Durch die [Zielwarteschlange](#) waren die Ziele bisher wohlgeordnet. Auf dieser Ordnung basierte die Auswahlreihenfolge der Ziele.

Diese Ordnung der Zielagenda wird aufgebrochen. Da jedoch sichergestellt werden muss, dass vor Auswahl eines Ziels alle Vorbedingungen erfüllt sind, ist für die Zielagenda weiterhin eine Halbordnung gemäß den Vorbedingungen der Ziele im Wartezustand definiert (s. Abbildung 3.11).

Soll ein neues Ziel ausgewählt werden, so geschieht dies nun basierend auf den [Aufmerksamkeitsgewichten](#) (s. Gleichung 3.2). Dabei wird G durch die Menge der Ziele in den Zuständen *Selectable* und *Active* gebildet.

Da sich in der Literatur unterschiedliche Formulierungen der SEEV-Formel finden, wurde der [Agentenkonfigurationsdatei](#) die Option `ai.e_formulation` hinzugefügt, mit

der zwischen der additiven und der multiplikativen Formulierung gewählt werden kann. Als Standardeinstellung wurde die additive Formulierung gewählt. Bei Wahl der multiplikativen Formulierung werden automatisch die Ereignisfunktionen aller Ziele mit einem künstlichen Ereignis initialisiert (vgl. Abschnitt 3.5).

Weitere Parameter für die Zielauswahl sind die Gewichte der Erwartungs- und Wertparameter. Sie sind während der gesamten Simulation konstant und können global in der Agentenkonfigurationsdatei über die Optionen `weight_expectancy` und `weight_value` definiert werden. Als Standardeinstellung haben beide Gewichte den Wert 1.

3.8 Zusammenfassung

In diesem Kapitel wurde das AIE-Modell zur dynamischen Simulation der Aufmerksamkeitsverteilung beschrieben. Es wurde dargelegt, dass sich die Anwendung vor allem auf Multitaskingsituationen konzentriert, in denen mehrere Informationsquellen gleichzeitig beobachtet werden müssen.

Um das komplexe Thema der Aufmerksamkeitsverteilung handhaben zu können, wurden eine Reihe von vereinfachenden Annahmen getroffen, die nachfolgend zusammengefasst aufgelistet sind.

Annahme 1: Die Wahrscheinlichkeitsverteilung der Ereignisursachen ändert sich innerhalb eines Simulationsszenarios nicht.

Annahme 2: Das AIE-Modell wird zur Modellierung von erfahrenen Nutzer verwendet.

Annahme 3: Das Erlernen und Nutzen von Ereignishäufigkeiten erfordert keinen zusätzlichen Aufwand.

Annahme 4: Das AIE-Modell besitzt nur Gültigkeit in Zusammenhang mit der Simulation einer Aufgabenbeschreibung ohne externe Störungen und ohne Notwendigkeit zur visuellen Suche.

Annahme 5: Kognitive Architekturen, die das AIE-Modell verwenden, implementieren einen Datenakquisealgorithmus.

Annahme 6: Das Verhalten von Menschen ist zielorientiert.

Annahme 7: In einer Architektur, die das AIE-Modell integriert, lassen sich Ereignisse als das Nutzen von Informationen zum Erreichen eines Zieles klar identifizieren.

Das AIE-Modell fokussiert insbesondere darauf, den Zusammenhang zwischen der Erwartung von Ereignissen und der Verteilung der Aufmerksamkeit zu simulieren. Im Vergleich zu anderen Modellen der Aufmerksamkeitsverteilung (s. Kapitel 2) ermöglicht es das AIE-Modell, Ereignisse automatisch während der Simulation zu bestimmen. Auf Basis der beobachteten Ereignisse wird eine automatische Operationalisierung der Erwartungsparameter vorgenommen, mit denen plausible Blicksequenzen erzeugt werden sollen. Hierzu wurden als ein Kernelement des AIE-Modells Ereignisfunktion eingeführt, die die Verteilung der zeitlichen Abstände von Informationsereignissen repräsentieren. Mittels der Ereignisfunktionen lassen sich auch Änderungen der Ereigniserwartung innerhalb kurzer Zeiträume von wenigen Sekunden simulieren. In bisherigen Aufmerksamkeitsmodellen wird die Erwartung typischerweise für wesentlich längere Zeiträume manuell definiert. Zudem wird mit dem AIE-Modell ein Ansatz aufgezeigt, wie sich die Bearbeitung von Aufgaben und

die Verteilung der Aufmerksamkeit eng integriert simulieren lässt. Schließlich wurden die Änderungen dargelegt, die nötig waren, um das AIE-Modell in die kognitive Architektur CASCaS zu integrieren.

In den folgenden Kapiteln 4 und 5 wird das in CASCaS integrierte AIE-Modell anhand zweier Anwendungsfälle evaluiert. Um den Effekt der eingeführten automatischen Operationalisierung zu untersuchen, werden die kognitiven Agenten, die für die beiden Anwendungsfälle erzeugt wurden, mit verschiedenen Variationen des AIE-Modells simuliert. Dabei werden Simulationen durchgeführt, bei denen anstelle der Ereignisfunktionen lediglich die durchschnittlichen **Ereignisraten** oder aber feste, a priori definierte Werte für die Erwartungsparameter verwendet werden.

Kapitel 4

Evaluation I: Senders' Monitoring-Aufgabe

Das Ziel des AIE-Modells ist es, das menschliche Blickverhalten in Abhängigkeit von [Ereignisraten](#) und [Aufgabenprioritäten](#) zu simulieren. Typischerweise sind dies jedoch nicht die einzigen Faktoren, die das Blickverhalten beeinflussen. In den komplexen Situationen, denen wir im Alltag begegnen, treten eine Reihe von Störfaktoren auf, die es erschweren, zu bestimmen, welche Faktoren ursächlich für das beobachtete Verhalten sind.

Das AIE-Modell wird daher in einem ersten Schritt anhand einer Laboraufgabe evaluiert, die Störeinflüsse weitestgehend eliminiert und kontrolliert. Hierzu wurde die bereits in Abschnitt [2.1.4.1](#) angesprochene [Monitoring-Aufgabe](#) von [Senders \(1983\)](#) gewählt. Die Wahl fiel auf diese Aufgabe, da sie sehr einfach aufgebaut ist und darauf fokussiert, das Blickverhalten von Probanden in Abhängigkeit von verschiedenen Ereignisraten zu untersuchen. Zudem können für die Evaluierung des AIE-Modells Ergebnisse zu Blickfrequenzen und -dauern aus Senders' Versuchen herangezogen werden. Senders untersuchte die Auswirkungen von verschiedenen Konfigurationen der Monitoring-Aufgabe auf das Blickverhalten. Für die Evaluierung werden hier jedoch nur Ergebnisse von einigen ausgewählten Aufgabenkonfigurationen verwendet.

Des Weiteren eignet sich diese Aufgabe gut, da sie im Bereich der Aufmerksamkeitsmodellierung sehr bekannt ist. Sie wurde in späteren Jahren in verschiedenen Variationen wieder aufgegriffen und erweitert. In Senders' Experimenten korrelierten die Ereignisraten und [Signalbandbreiten](#) perfekt. Für Anzeigeeinstrumente in realen Anwendungen kann dies jedoch nicht vorausgesetzt werden. [Miller et al. \(2004\)](#) variierten daher die Ereignisraten und [Signalbandbreiten](#) unabhängig voneinander, um zu untersuchen, welcher dieser Faktoren ausschlaggebend für Änderungen im Blickverhalten ist. Zudem wiesen sie den Anzeigeeinstrumenten Prioritäten zu, um zusätzlich den Einfluss eines Wertparameters zu berücksichtigen. Eine weitere Studie ([Miller und Fu, 2007](#)) erzeugte wiederkehrende Muster in den Signalen, um zu untersuchen, inwieweit die Probanden diese nutzen, um ihr Überwachungsverhalten zu optimieren.

Für die Evaluierung des AIE-Modells wird in diesem Kapitel auf Versuchsergebnisse von [Senders \(1983, 1964\)](#) zurückgegriffen. Im weiteren Verlauf des Kapitels werden die Versuchsaufbauten dieser Versuche kurz wiedergegeben und eine Auswahl der Versuchskonfigurationen vorgenommen, die für die Evaluierung berücksichtigt




Abbildung 4.1 – Senders' Versuchsaufbau für vier Anzeigeeinstrumente.

werden. Für detailliertere Angaben zu den Versuchen sei auf die Originalquellen verwiesen. Anschließend wird ein in CASCaS entwickelter kognitiver Agent präsentiert, der mit Senders' Aufgabe interagieren kann. Schließlich werden Simulationsergebnisse vorgestellt, die mit unterschiedlichen Variationen des kognitiven Agenten erzielt wurden. Dabei werden die Simulationsergebnisse mit den Versuchsdaten verglichen und verschiedene Verhaltensaspekte des Agenten im Detail diskutiert.

4.1 Senders' Experimentreihe

Senders führte mehrere Experimenten durch, bei denen der grundlegende Versuchsaufbau stets identisch war. Insgesamt beschrieb er fünf Experimente, von denen hier jedoch nur drei verwendet werden sollen. Es folgt eine zusammenfassende Beschreibung des Versuchsaufbaus nach Senders (1964, 1983).

4.1.1 Genereller Versuchsaufbau

Die Aufgabe der Versuchspersonen bestand darin eine Reihe von analogen Anzeigeeinstrumenten zu beobachten. Auf den Anzeigeeinstrumenten wurden pseudozufällige Signale mit unterschiedlichen Bandbreiten präsentiert, die aus insgesamt 40 Sinusoiden zusammengesetzt wurden. Abbildung 4.1 zeigt den Versuchsaufbau des ersten Experiments rekonstruiert nach Senders (1964, 1983). Der Wertebereich der Anzeigeeinstrumente reichte von $-50 \mu A$ bis $50 \mu A$. Die Versuchspersonen wurden instruiert, einen Knopf zu drücken, sobald eines der Signale in einen Alarmbereich gerät. Dies war der Fall, wenn das Signal unter $-45 \mu A$ sank oder über $45 \mu A$ stieg.

Die Versuchspersonen führten die Aufgabe über mehrere Tage für jeweils eine Stunde aus. Währenddessen waren ihre Köpfe durch eine Kinnstütze fixiert und ihre Augenbewegungen wurden mit einer Kamera aufgezeichnet.

4.1.2 Unterschiede in den Experimenten

Es folgt nun eine kurze Beschreibung zu den fünf Versuchen und den Unterschieden zwischen diesen.

Versuch 1 untersuchte das Blickverhalten beim Überwachen von vier kontinuierlichen Signalen (s. Abbildung 4.1). Jede Versuchsperson führte die Aufgabe über 30 Tage für je eine Stunde durch. Dabei wurden jeweils die ersten und letzten drei Minuten eines jeden Tages ausgewertet.




Abbildung 4.2 – Senders' Versuchsaufbau für sechs Anzeigeeinstrumente.

Versuch 2 war ähnlich aufgebaut wie Versuch 1, jedoch wurden anstelle von vier nun sechs kontinuierliche Signale verwendet, die wie in Abbildung 4.2 angeordnet wurden. Die Abmessungen des Versuchsaufbaus waren ansonsten beinahe identisch. Der Abstand der Versuchspersonen zum Instrumentendisplay betrug 75 cm. Die Versuchspersonen führten die Aufgabe anstelle von 30 Tagen lediglich für je zehn Tage durch, wobei nur die letzten elf Minuten des zehnten Tages ausgewertet wurden. Dasselbe gilt für die Versuche 3 bis 5.

Versuch 3 war aufgebaut wie Versuch 2, ersetzte jedoch die pseudozufällig erzeugten Signale durch tatsächlich zufällige Signale. Der dafür nötige Versuchsaufbau erforderte es, dass andere Signalfrequenzen verwendet wurden als in den anderen Experimenten (s. Tabelle 4.1).

Versuch 4 war aufgebaut wie Versuch 2, allerdings korrelierte eines der Signale mit einem [Korrelationskoeffizienten](#) von $r = 0.81$ mit einem anderen Signal. Dieser Aufbau sollte untersuchen, ob und wie die Versuchspersonen den Zusammenhang der Signale nutzten, um ihr Blickverhalten für die Überwachungsaufgabe zu optimieren.

Versuch 5 war aufgebaut wie Versuch 2, zeigte jedoch eines der kontinuierlichen Signale über eine diskrete Anzeige an, welche lediglich die Werte *Alarm* und *kein Alarm* darstellte.

Experiment	Probanden	Signalfrequenzen pro Anzeigeeinstrument [Hz]					
		1	2	3	4	5	6
1: Vier Instrumente	5	0.08	0.16	0.32	0.64	-	-
2: Sechs Instrumente	3	0.03	0.05	0.12	0.20	0.32	0.48
3: Zufälliges Signal	2	0.02	0.04	0.08	0.16	0.32	0.64
4: Korreliertes Signal	5	0.03	0.05	0.12	0.20	0.32	0.48
5: Diskretes Signal	5	0.03	0.05	0.12	0.20	0.32	0.48

Tabelle 4.1 – Verwendete Bandbreiten in den fünf Experimente.

Die **Bandbreiten**, die Senders in den einzelnen Experimenten verwendete, sind in Tabelle 4.1 aufgelistet. Sie summieren sich immer zu 1.2 Hz bzw. 1.26 Hz auf, da Senders in diesem Bereich eine vollständige Auslastung der Probanden erwartete. Die Simulationen des AIE-Modells wurden fast ausschließlich mit den Daten aus Experiment 1, 2 und 3 verglichen. Die in Experiment 4 und 5 betrachteten Aspekte der Signalkorrelation bzw. der Differenzierung zwischen der diskreten und kontinuierlichen Anzeige von Signalen werden von dem in Abschnitt 4.2 präsentierten **kognitiven Agenten** nicht berücksichtigt. Die Ergebnisse dieser Experimente werden daher nicht verwendet. Die einzige Ausnahme bildet die Analyse der Verhaltensvariabilität. Hierauf wird in Abschnitt 4.3.5 eingegangen.

4.2 Agentenmodell

Zur Evaluierung des AIE-Modells wurde ein kognitiver Agent in CASCaS entwickelt. Die Aufgabenprozedur dieses Agenten wird nun beschrieben.

Die im vorherigen Abschnitt dargestellte Aufgabe der Probanden lässt sich zusammenfassend beschreiben, als das Erkennen von Alarmen auf einer Reihe von n Anzeigeelementen. Dies wird im Aufgabenmodell des kognitiven Agenten durch das Top-Level-Ziel `detect_alarms` abgebildet. Um Alarme zu erkennen, müssen die Probanden jedes Instrument beobachten. Für jedes der n Instrumente wird daher ein Unterziel `observe_gauge_i` angelegt. Hieraus ergibt sich eine sehr einfache Struktur der Zielhierarchie, die in Abbildung 4.3 zu sehen ist.

Zu Beginn der Simulation wird das Top-Level-Ziel `detect_alarms` aktiviert. Die Produktionsregeln für dieses Ziel sind im Prozedurabschnitt 4.1 abgebildet. Regel 1 wird gefeuert, wenn auf dem Bildschirm vier Anzeigeelemente dargestellt werden. Für jedes der Anzeigeelemente wird beim Feuern das entsprechende Ziel `observe_gauge_i` aktiviert. Werden dagegen sechs Anzeigeelemente dargestellt, so wird Regel 2 gefeuert und es werden sechs Unterziele aktiviert.

Um die Regelbedingungen für diese beiden Produktionsregeln auszuwerten, benötigt der Agent Informationen zur Anzahl der Instrumente auf dem Bildschirm (`screen.number_of_gauges`). Da dem Agenten zu Beginn der Simulation diese Informationen fehlen, wird automatisch die Wahrnehmungsregel 3 gefeuert, die die Motor Komponente anweist, den Blick auf den Bildschirm zu richten. Um die Blickbewegungen zu simulieren, wurde für die beiden Versuchsbedingungen mit vier bzw. sechs Anzeigeelementen jeweils eine Topologie (s. Abschnitt 2.3.3.1) erzeugt, die den Versuchsaufbau nach der Beschreibung von Senders abbildet (vgl. Abbildungen 4.1 und 4.2). In jeder Topologie ist jeweils eine Informationsquelle `screen` in der Größe des gesamten Bildschirms definiert, die die Information zur Anzahl der Anzeigeelemente beinhaltet (`number_of_gauges`). Zudem ist für jedes Anzeigeelement eine 76 x 76 mm große Informationsquelle definiert, über die der Agent die Position des




Abbildung 4.3 – Zielhierarchie des Aufgabenmodells zu den Experimentaufgaben von Senders

Prozedurabschnitt 4.1 – Struktur des Top-Level-Ziels `observe_gauges`

```

// This sets the initial goal of the agent model to the top-level goal detect_alarms
goal_module {
  default_goal(detect_alarms)
}

// This rule fires, if 4 gauges are displayed on the screen
rule=1, name=detect_alarms, type=regular
  Retrieve, screen
  Condition, (screen.number_of_gauges == 4)
  ==>
  Goal, name=observe_gauge_1, mode=persistent, value=1.0
  Goal, name=observe_gauge_2, mode=persistent, value=1.0
  Goal, name=observe_gauge_3, mode=persistent, value=1.0
  Goal, name=observe_gauge_4, mode=persistent, value=1.0
;

// This rule fires, if 6 gauges are displayed on the screen
rule=2, name=detect_alarms, type=regular
  Retrieve, screen
  Condition, (screen.number_of_gauges == 6)
  ==>
  Goal, name=observe_gauge_1, mode=persistent, value=1.0
  Goal, name=observe_gauge_2, mode=persistent, value=1.0
  Goal, name=observe_gauge_3, mode=persistent, value=1.0
  Goal, name=observe_gauge_4, mode=persistent, value=1.0
  Goal, name=observe_gauge_5, mode=persistent, value=1.0
  Goal, name=observe_gauge_6, mode=persistent, value=1.0
;

// This rule fires at the beginning to move the gaze of the agent model to the screen
rule=3, goal=detect_alarms, type=percept
  ==>
  LookAt, screen
;

/* A subgoal is defined for the observation of each gauge. The structure of a subgoal is
 * identical for each gauge. These instructions add the production rules for each subgoal.*/
#include ./config/procedures/senderstask/gauge1.proc
#include ./config/procedures/senderstask/gauge2.proc
#include ./config/procedures/senderstask/gauge3.proc
#include ./config/procedures/senderstask/gauge4.proc
#include ./config/procedures/senderstask/gauge5.proc
#include ./config/procedures/senderstask/gauge6.proc

```

Zeigers ablesen kann und erkennt, wenn sich der Zeiger in eine Alarmregion bewegt hat.

Um das AIE-Modell anwenden zu können, wird für jedes Ziel der Wertparameter benötigt. Da in Senders Experimenten für die Probanden keines der Instrumente wichtiger war als die anderen, wurde für alle Ziele derselbe Wert gewählt (`value=1.0`).

Die Aufgabe, ein Instrument zu beobachten, ist nicht abgeschlossen, nachdem das Instrument einmalig betrachtet wurde, sondern erfordert eine ständige Beobachtung. Die Ziele sind daher als persistent markiert (`mode=persistent`).

Die Produktionsregeln für jedes Unterziel sind identisch aufgebaut. In Prozedurabschnitt 4.2 ist ein Template für diese Produktionsregeln dargestellt. Die konkreten Produktionsregeln für die Beobachtung eines Instruments ergeben sich, wenn der Platzhalter `<i>` durch die Nummer des Instruments ersetzt wird.

Wählt der Agent das `i`-te Beobachtungsziel `observe_gauge_<i>` aus, so fehlt ihm zu Beginn die Information zum aktuellen Status des `i`-ten Anzeigeelements. Diese wird aber benötigt, um die Regelbedingungen der regulären Regeln auszuwerten. Daher wird zuerst die Wahrnehmungsregel (`<i>02`) gefeuert, um den Blick auf das entsprechende Anzeigeelement zu richten. Wenn der Agent die Informationen

Prozedurabschnitt 4.2 – Template für die Produktionsregeln zur Beobachtung eines Instruments

```

rule=<i>00, goal=observe_gauge_<i>, type=regular
  Retrieve, gauge<i>
  Condition, (gauge<i>.position < -45)
  Condition, (gauge<i>.alarm == 1)
  ==>
  Motor, right hand, push, instr=gauge<i>.alarmkey
  Memorize, gauge<i>.alarm, 0
;

rule=<i>01, goal=observe_gauge_<i>, type=regular
  Retrieve, gauge<i>
  Condition, (gauge<i>.position > 45)
  Condition, (gauge<i>.alarm == 1)
  ==>
  Motor, right hand, push, instr=gauge<i>.alarmkey
  Memorize, gauge<i>.alarm, 0
;

rule=<i>02, goal=observe_gauge_<i>, type=percept
  ==>
  LookAt, gauge<i>
;

rule=<i>03, goal=observe_gauge_<i>, type=waiting
  ==>
;

```

wahrgenommen hat, lassen sich im Prinzip drei Situationen unterscheiden. Die erste Produktionsregel (<i>00) wird gefeuert, wenn sich der Zeiger im negativen Alarmbereich unterhalb von $-45 \mu A$ befindet. Die zweite Produktionsregel (<i>01) wird dagegen gefeuert, wenn sich der Zeiger im Alarmbereich oberhalb von $45 \mu A$ befindet. Beide Regeln führen dazu, dass der Agent eine Taste drückt, um den erkannten Alarm anzuzeigen. In allen anderen Situationen, in denen sich der Zeiger nicht im Alarmbereich befindet, führt der Agent keine Handlung aus. Dies führt zum Feuern der Warteregeln (<i>03).

Dies ist bereits die vollständige Prozedur, die im Folgenden für den Agenten verwendet wird.

4.3 Simulationsergebnisse

Für eine erste Evaluierung des AIE-Modells wird der oben beschriebene Agent in verschiedenen Konfigurationen simuliert. Um die verschiedenen Konfigurationen im Text einfach zu kennzeichnen, werden nun kurze Bezeichner für die Konfiguration der Agenten eingeführt.

In einem ersten Schritt wird der Agent ohne Verwendung des AIE-Modells simuliert, um die aktuelle Situation der Aufmerksamkeitssteuerung in CASCaS zu charakterisieren. Dieser Agent wird mit **-AIE** bezeichnet.

Anschließend wird die gleiche Simulation mit dem AIE-Modell durchgeführt. Hierbei besteht die Möglichkeit, die multiplikative Variante der SEEV-Formel zu verwenden oder die additive. Die Konfiguration mit der multiplikativen Variante wird mit **AIE*** und die mit der additiven Variante mit **AIE+** bezeichnet.

Für eine Sensitivitätsanalyse werden die Gewichtungsfaktoren U und V für die Erwartungs- bzw. Wertparameter variiert. Die resultierenden Konfigurationen werden mit **AIE_{U,V}⁺** bezeichnet. Die Ergebnisse der Sensitivitätsanalyse sowie der Ver-

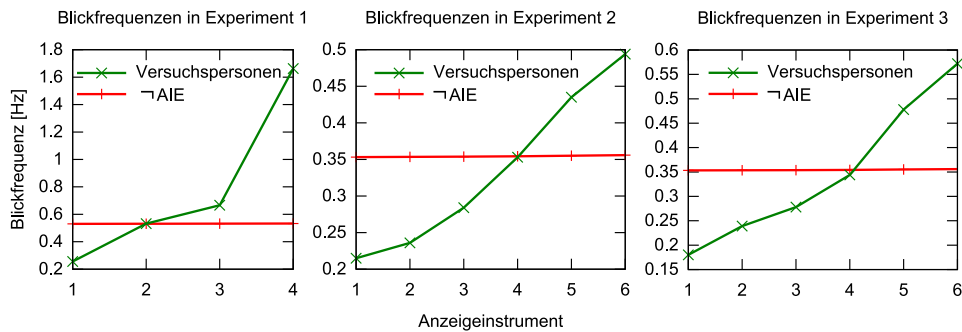


Abbildung 4.4 – Blickfrequenzen des \neg AIE-Agenten im Vergleich zu den Blickfrequenzen der Versuchspersonen

gleich zwischen dem AIE⁺- und dem AIE^{*}-Agenten wurden bereits in (Wortelen und Lüdtkke, 2013) vorgestellt.

Um einen Vergleich zu Ansätzen wie in MIDAS (Gore et al., 2009) zu ermöglichen, bei denen statische Werte für die SEEV-Parameter verwendet werden, wird der Agent in einer Konfiguration simuliert, die zwar die Erwartungs- und Wertparameter benutzt, um die Aufmerksamkeitsgewichte zur Steuerung der Aufmerksamkeit zu berechnen (s. Gleichung 3.1, S. 69). Jedoch werden die Erwartungsparameter nicht an die beobachtete Ereignisrate adaptiert, sondern statische, vorab bestimmte Werte verwendet. Diese Konfiguration wird mit SE⁺ bzw. SE^{*} (Statische Erwartungsparameter) bezeichnet.

Die Ergebnisse der Simulationen werden zum Teil grafisch dargestellt. In Anhang C finden sich die Daten zu den Grafiken jeweils auch in tabellarischer Form.

4.3.1 Simulation ohne AIE-Modell

Um den Effekt, den das AIE-Modell auf das Blickverhalten des Agenten hat, zu demonstrieren, wurden Simulationen unter den Versuchsbedingungen der ersten drei Experimente durchgeführt. In Kapitel 3 wurde bereits erwähnt, dass die Integration des AIE-Modells in eine kognitive Architektur die Evaluierung des AIE-Modells erschwert, da die Verhaltenseffekte, die sich bei der Simulation eines kognitiven Agenten zeigen, nicht nur vom AIE-Modell abhängen, sondern von allen in der Architektur implementierten Prozessen. Daher wurde in einem ersten Schritt das AIE-Modell in CASCaS deaktiviert (\neg AIE-Agent), um eine Vergleichsbasis zu den späteren Simulationen mit aktiviertem AIE-Modell zu schaffen. Jede Versuchsbedingung wurde für 30 Stunden (Simulationszeit) simuliert.

Ohne das AIE-Modell werden bei der Simulation der Aufmerksamkeitsverteilung die Häufigkeiten von Ereignissen nicht berücksichtigt. Die Aufmerksamkeit wird daher gleichmäßig auf die Anzeigeeinstrumente verteilt. Dies ist in Abbildung 4.4 zu sehen. Für alle drei Versuchsbedingungen sind dort die durchschnittlichen Blickfrequenzen während der 30 Simulationsstunden für jedes Anzeigeeinstrument abgebildet. Die Anzeigeeinstrumente sind aufsteigend nach ihrer Signalfrequenz sortiert. Zum Vergleich sind zudem die durchschnittlichen Blickfrequenzen der Versuchspersonen aus Senders' Studien aufgetragen. Es ist gut zu erkennen, dass die Blickfrequenzen des \neg AIE-Agenten nur von der Anzahl der Anzeigeeinstrumente abhängen, nicht jedoch von der Signalfrequenz der einzelnen Anzeigen, wie dies bei den Versuchspersonen der Fall ist. Die Gesamtblickfrequenz des \neg AIE-Agenten beträgt 2.126 Hz. Bei vier

Anzeigeeinstrumenten ergibt sich daher für jedes Instrument eine Blickfrequenz von 0.531 Hz und bei sechs Instrumenten eine Blickfrequenz von 0.354 Hz.

Die Versuchsdaten zeigen jedoch, dass die Blickfrequenz der Probanden mit der Signalfrequenz der Anzeigeeinstrumente ansteigt. Der \neg AIE-Agent ist nicht in der Lage diesen Effekt wiederzugeben.

4.3.2 Simulation mit AIE-Modell

Für die Simulationen mit aktiviertem AIE-Modell wurde dieselbe Aufgabenprozedur verwendet. Der einzige Unterschied zur vorherigen Simulation besteht lediglich in der durch das AIE-Modell beeinflussten Zielauswahl.

In der Literatur finden sich bei der Verwendung des SEEV-Modells zwei Varianten zur Kombination des Erwartungs- und des Wertfaktors. Häufig werden die beiden Einflussfaktoren über Multiplikation verknüpft (Horrey et al., 2006, 2005; Wickens et al., 2001, 2003a; Steelman-Allen, 2011; Fleetwood, 2005). Eine additive Kombination findet sich bei Gore et al. (2009). Wickens et al. (2008) und Byrne und Kirlik (2004) verglichen die Vorhersagen beider Varianten. In beiden Studien wurde die additive Variante jeweils leicht, aber nicht klar präferiert.

Da die Frage, auf welche Weise die Faktoren am besten verknüpft werden, noch unklar scheint, werden hier nun beide Varianten simuliert und mit dem Verhalten der Versuchspersonen verglichen. Die additive Variante wird mit AIE^+ und die multiplikative mit AIE^* bezeichnet. Für diese Simulationen wurden die Erwartungs- und Wertparameter identisch gewichtet ($U = V = 1$).

Jede der drei Versuchsbedingungen wurde wieder für 30 Stunden simuliert. Im Vergleich zu den Simulationen des \neg AIE-Agenten gibt es nun jedoch einen wichtigen Unterschied im Simulationsaufbau. Das Verhalten des \neg AIE-Agenten ist in den ersten Minuten der Simulation ähnlich wie das in den letzten Minuten der Simulation, da das AIE-Modell deaktiviert ist. Wird nun jedoch das AIE-Modell aktiviert, so treten Lerneffekte auf. Der Agent besitzt zu Beginn der Simulation kein Wissen über die Häufigkeit von Ereignissen. Erst mit der Zeit nimmt er Ereignisse wahr, wodurch sich die Ereignisfunktion ausprägen. Dadurch kann sich das Verhalten des Agenten über die Zeit ändern. Es wurden nun zehn Simulationen über je drei Stunden durchgeführt. Von den drei Stunden ist jeweils nur die letzte in die Auswertung eingeflossen, da nach den ersten zwei Stunden nur noch wenige Lerneffekte zu beobachten waren. In Abschnitt 4.3.4 werden die Lerneffekte näher untersucht. Im Folgenden werden die Ergebnisse der Simulationen beschrieben.

4.3.2.1 Additive Formulierung

Die Blickfrequenzen, die sich bei Verwendung der additiven Formulierung für die ersten drei Experimente ergeben, sind in Abbildung 4.5 zu sehen. Neben den Blickfrequenzen, die aus der Simulation des AIE^+ -Agenten ermittelt wurden, sind auch die experimentell gemessenen Frequenzen aufgetragen.

Um die Anpassungsgüte eines Modells gegenüber Vergleichsdaten von menschlichem Verhalten zu untersuchen, sollte sowohl die Ähnlichkeit des Trends, als auch die Ähnlichkeit der absoluten Werte betrachtet werden (Schunn und Wallach, 2005; Fum et al., 2007).

In Abbildung 4.5 ist deutlich zu erkennen, dass der allgemeine Trend zwischen Versuchspersonen und Modell übereinstimmt. Je höher die Alarmfrequenz eines Anzeigeeinstruments ist, desto höher ist auch die Blickfrequenz zu diesem Instrument. Es ergibt sich ein Bestimmtheitsmaß von $R^2 = 0.851$ für das erste Experiment




Abbildung 4.5 – Blickfrequenzen des AIE⁺-Agenten im Vergleich zu den Blickfrequenzen der Versuchspersonen

und $R^2 = 0.996$ bzw. $R^2 = 0.984$ für das zweite und dritte Experiment. Deutlich ist jedoch auch zu erkennen, dass die absoluten Werte der Blickfrequenzen im zweiten und dritten Experiment wesentlich besser übereinstimmen als im ersten Experiment. Es ergibt sich eine **Root-Mean-Square Deviation (RMSD)** von 1.1 Hz für das erste Experiment gegenüber 0.04 Hz und 0.09 Hz für das zweite und dritte Experiment.

Insbesondere ist die **Gesamtblickfrequenz** des AIE⁺-Agenten, die sich aus der Summe der Frequenzen zu allen Instrumenten ergibt, im ersten Experiment mit 1.9 Hz deutlich geringer als die Gesamtblickfrequenz der Versuchspersonen (3.1 Hz). Allerdings ist die Gesamtblickfrequenz der Versuchspersonen auch nur in diesem Experiment so groß. Im zweiten und dritten Experiment wurden mit 2.0 Hz und 2.1 Hz Werte gemessen, die ungefähr den Blickfrequenzen des kognitiven Agenten entsprechen.

Eine mögliche Ursache für die hohe Frequenz im ersten Experiment könnte in der längeren Trainingszeit (30 Tage anstelle von 10 Tagen) liegen, die es den Versuchspersonen im ersten Experiment erlaubte, höhere Frequenzen zu erzielen. Dagegen spricht jedoch die Beobachtung von [Senders \(1983, S.59\)](#), nach der die Versuchspersonen bereits nach dem dritten Tag ein stabiles Verhalten zeigten. Weitere Ursachen könnten in der geringeren Anzahl der Anzeigeelemente liegen oder in interindividuellen Unterschieden der Versuchspersonen, da nur eine geringe Anzahl an Versuchspersonen an dem Experiment teilnahm. Der tatsächliche Grund für die hohe Frequenz bleibt jedoch unklar und konnte auch von [Senders \(1983\)](#) nicht identifiziert werden.

Um eine so hohe Blickfrequenz wie die Versuchspersonen in Experiment eins zu erzielen, müssen die Sakkaden- und Fixationsdauern enorm kurz sein und zusammen durchschnittlich etwa 320 ms betragen. Diese Zeiten beeinflusst das AIE-Modell jedoch nicht. Für die Simulation der Blickbewegungen wird dagegen auf die in CASCaS implementierten Prozesse der Low-Level-Vision zurückgegriffen (s. Abschnitt 2.3.3.2). Diese gehen jedoch bereits für Fixationen von einer durchschnittlichen Dauer von 370 ms aus.

Der Fall illustriert gut, dass für die Simulation des Blickverhaltens nicht nur die Frage geklärt werden muss, was das Ziel der nächsten Fixation ist (**Ablaufplanungsalgorithmus**), sondern auch wie lange jede Fixation und jede Sakkade dauert (**Datenakquisealgorithmus**). Das AIE-Modell beantwortet nur die erste Frage und ist daher für die zweite Frage auf geeignete Modelle im Rahmenwerk angewiesen, in das es eingebettet ist (hier: CASCaS).

Bei der Bewertung von Designs für Benutzeroberflächen können neben den Blickfre-




Abbildung 4.6 – Transitionswahrscheinlichkeiten der Versuchspersonen im Vergleich zu den Ergebnissen von verschiedenen Agenten. Der Punkt $p_{1,2}$ bezeichnet die Transitionswahrscheinlichkeit von Blicken zwischen Instrument 1 und 2. Links: \neg AIE-Agent ($R^2=0.01$). Mitte: AIE⁺-Agent ($R^2=0.87$). Rechts: AIE^{*}-Agent ($R^2=0.81$).

quenzen auch [Transitionswahrscheinlichkeiten](#) nützliche Informationen liefern (vgl. Abschnitt 2.1.1). Senders gibt Transitionswahrscheinlichkeiten lediglich für Experiment 1 an. In [Abbildung 4.6](#) sind die Korrelationen der Transitionswahrscheinlichkeiten für drei verschiedene Agentenkonfigurationen gegenüber den in Experiment 1 gemessenen Werten dargestellt. Ein Datenpunkt $p_{i,j}$ bezeichnet hier die Wahrscheinlichkeit einer Blicktransition zwischen Instrument i und Instrument j . Das linke Diagramm stellt die Wahrscheinlichkeiten für einen Agenten mit deaktiviertem AIE-Modell dar. Es zeigt sich kein Zusammenhang zwischen den Experiment- und den Simulationsergebnissen ($R^2=0.01$). Dies ist nicht verwunderlich, da CASCaS in der bisherigen Implementierung die aktiven Ziele auf der Agenda in der Reihenfolge bearbeitet, in der sie der Zielagenda hinzugefügt wurden. Da die Ziele `observe_gauge_1`, `observe_gauge_2`, `observe_gauge_3`, `observe_gauge_4` in dieser Reihenfolge aktiviert wurden, ergibt sich die wiederholende Blicksequenz: Instrument 1 \rightarrow Instrument 2 \rightarrow Instrument 3 \rightarrow Instrument 4. Die betreffenden Transitionen treten alle gleich häufig auf, während alle übrigen (z.B. $p_{1,3}$) niemals auftreten.

Im mittleren Diagramm erkennt man, dass sich dies ändert bei Verwendung des AIE⁺-Agenten. Zwischen den Transitionswahrscheinlichkeiten des Agenten und denen der Versuchspersonen ist ein starker Zusammenhang zu erkennen ($R^2=0.87$). Allerdings zeigt sich auch, dass die Steigung der Korrelationsgeraden relativ gering ausfällt. Bei näherer Betrachtung fällt insbesondere auf, dass der AIE⁺-Agent eine deutlich höhere Transitionswahrscheinlichkeit zwischen zwei Instrumenten mit niedriger Ereignisrate (z.B. $p_{1,2}$) erzeugt, als dies bei den Versuchspersonen beobachtet wurde. Umgekehrt werden Transitionen zwischen Instrumenten mit hohen Ereignisraten deutlich seltener durch das AIE-Modell erzeugt. Dies ist ein Indiz dafür, dass die Versuchspersonen es tendenziell vermeiden, zwei aufeinander folgende Blicke auf niederfrequente Informationsquellen zu richten.

4.3.2.2 Multiplikative Formulierung

Auf die gleiche Weise wie im vorherigen Abschnitt wurde auch das Verhalten eines Agenten untersucht, der anstelle der additiven SEEV-Formulierung eine multiplikative verwendet (AIE^{*}). Die erzielten Blickfrequenzen sind in [Abbildung 4.7](#) dargestellt. Es ist bereits rein visuell gut ersichtlich, dass sowohl der Trend als auch die Übereinstimmung der absoluten Werte schlechter ausfallen, als bei der additiven




Abbildung 4.7 – Blickfrequenzen des AIE*-Agenten im Vergleich zu den Blickfrequenzen der Versuchspersonen

Formulierung. Die RMSD ist in den drei Versuchen um 0.07 Hz bis 0.15 Hz im Vergleich zur additiven Variante gestiegen.

Zudem hat sich auch der Korrelationskoeffizient verschlechtert. Für das erste Experiment wurde ein Koeffizient von lediglich $R^2=0.657$ ermittelt. Für das zweite und dritte Experiment ging der Koeffizient leicht auf $R^2=0.939$ beziehungsweise $R^2=0.941$ zurück. Für diese beiden Experimente zeigt sich insbesondere, dass das Modell die Blickfrequenzen zu den Instrumenten mit niederfrequenten Ereignisraten unterschätzt. Diese Beobachtungen sprechen dafür, der additiven Formulierung Vorrang gegenüber der multiplikativen zu geben.

Etwas anders sieht es aus, wenn man die Transitionswahrscheinlichkeiten betrachtet. Diese sind im rechten Diagramm in Abbildung 4.6 dargestellt. Die Werte korrelieren mit $R^2=0.81$ zwar weniger gut als die Werte, die mit der additiven Formulierung erzielt wurden. Allerdings werden die Transitionswahrscheinlichkeiten zwischen Instrumenten mit niederfrequenten Ereignisraten nicht so stark überschätzt, wie bei der additiven Formulierung. Ebenso werden die Wahrscheinlichkeiten zwischen Instrumenten mit hochfrequenten Ereignisraten weniger stark unterschätzt. Das spiegelt sich in einer höheren Übereinstimmung der absoluten Werte wider. Die RMSD liegt für die additive Formulierung bei 0.071. Für die multiplikative Formulierung beträgt diese nur 0.051.

Im Vergleich zwischen additiver und multiplikativer Formulierung decken sich die Ergebnisse hier mit den Ergebnissen von Wickens et al. (2008) und Byrne und Kirlik (2004), die bei ihren Studien ebenfalls eine etwas bessere Modellanpassungsgüte mit der additiven Formulierung erzielten. Lediglich bei Betrachtung der Transitionswahrscheinlichkeiten lässt sich keine der beiden Varianten klar präferieren.

4.3.2.3 Sensitivität der Gewichtungsfaktoren

Bei den bisher vorgestellten Ergebnissen wurden die Gewichte U und V für die Erwartungs- und Wertparameter jeweils identisch gewählt, da dieses Vorgehen gängige Praxis in der Literatur ist (s. Abschnitt 2.1.4.3). Tatsächlich wird eine abweichende Gewichtung der Parameter in der Literatur nur sehr selten betrachtet.

Horrey et al. (2005, S.48, 57) merken zwar an, dass in ihren Experimenten zum Blickverhalten von Autofahrern die Aufgabenprioritäten, über die Wertparameter bestimmt wurden, einen etwas größeren Effekt auf die Blickverteilung hatten als die Ereignisraten. Für die Modellierung der Aufmerksamkeitsverteilung legten sie allerdings keine Gewichtung der Parameter fest. Eine Gewichtung der SEEV-Parameter ist in der Implementierung des Noticing-SEEV (N-SEEV)-

Modells (Steelman-Allen et al., 2009) möglich, das auf dem SEEV-Modell basiert. Die Gewichte der SEEV-Parameter werden im N-SEEV-Modell als *pertinence*-Werte bezeichnet. Bei dieser Bezeichnung ist Vorsicht geboten, da die Nutzung im N-SEEV-Modell nicht mit der Art und Weise übereinstimmt, mit der sie Bundesen (1990) ursprünglich verwendet. Während Bundesen damit die Gewichtung von Gruppen von Objekten mit einer bestimmten Ausprägung einer Eigenschaft (z. B. Farbe = rot) vornimmt, gewichtet das N-SEEV-Modell den Einfluss der SEEV-Parameter und damit im Prinzip den Einfluss einer gesamten Eigenschaft wie beispielsweise der Auffälligkeit von Objekten.

Steelman-Allen (2011) präsentiert einige Anwendungsfälle, bei denen die pertinence-Werte von Domänenexperten über eine Alles-oder-Nichts-Strategie bestimmt wurden, bei der ihnen entweder der Wert null oder eins zugewiesen wurde. Für alle Situationen in allen Anwendungsfällen wurden die Werte für Erwartung und Informationswert immer mit eins angegeben. Das heißt, auch hier wurde praktisch der Effekt von unterschiedlichen Gewichtungen für diese beiden Parameter nicht untersucht.

Auch wenn die Gewichte selten berücksichtigt werden, so stellen sie dennoch freie Parameter des AIE-Modells dar. Bei quantitativen Modellen mit freien Parametern ist die Bewertung des Modells allein auf Basis der *Modellanpassungsgüte* nicht ausreichend. Roberts und Pashler (2000) argumentieren, dass weitere Fragen bezüglich der freien Parameter geklärt werden müssen. Unter anderem sollte untersucht werden, welche Daten das Modell potentiell generieren kann, wenn Parameter aus einem sinnvollen Bereich gewählt werden. Zudem sollte auch analysiert werden, welche Daten das Modell nicht generieren kann.

Die Erwartungs- und Wertparameter der einzelnen Ziele stellen für die hier betrachtete Aufgabe von Senders keine freien Parameter des AIE-Modells dar. Die Versuchspersonen sollten keines der Anzeigeinstrumente priorisieren. Daher sind gleiche Wertparameter für alle Ziele die einzig sinnvolle Parameterkombination. Aufgrund der Normalisierung spielt der absolute Wert der Wertparameter dann keine Rolle, sondern nur ihr Verhältnis. Für die Erwartungsparameter ist dagegen die Operationalisierung über die *Ereignisfunktion* fest durch das AIE-Modell vorgegeben. Sie stellen somit auch keine freien Parameter dar. Als freie Parameter verbleiben daher für die additive Variante vor allem die Gewichte U und V .

Prinzipiell ist aber auch die Aufgabenprozedur ein freier Parameter. Ihre Definition unterliegt u. a. der Erfahrung des Modellierers. Inwieweit sie eine sinnvolle Abstraktion für die mentale Aufgabenrepräsentation der Versuchspersonen darstellt, ist schwer zu bestimmen und immer mit Unsicherheit verbunden. Einen möglichen Ansatz, die Sensitivität bezüglich der Aufgabenprozedur zu untersuchen, bietet die Eingrenzungs-Heuristik (engl.: bracketing heuristic) von Kieras und Meyer (2000), bei der extreme Varianten des Aufgabenmodells identifiziert werden, um einerseits den Raum an möglichen Verhaltensweisen zu schätzen und um andererseits die Vorhersagen des Modells in Relation zu den extremen Varianten zu bewerten. Da Senders' Laboraufgabe jedoch äußerst einfach ist, werden alternative Aufgabenprozeduren hier nicht betrachtet.

Im Folgenden werden nun lediglich die Gewichte U und V näher beleuchtet. Für das AIE-Modell spielen die absoluten Werte von U und V keine Rolle, sondern nur ihr Verhältnis. Um den Einfluss der Gewichtung zu demonstrieren, wurden daher die Simulationen mit der additiven Formulierung mit 16 verschiedenen Gewichtungsverhältnissen für U/V wiederholt:

$0/1, 1/5, 1/4, 1/3, 1/2, 2/3, 3/4, 4/5, 1/1, 5/4, 4/3, 3/2, 2/1, 3/1, 4/1, 5/1, \infty$

Für jedes Verhältnis wurden zehn dreistündige Simulationen durchgeführt, von de-




Abbildung 4.8 – Blickfrequenzen des AIE⁺-Agenten im zweiten Experiment bei unterschiedlichen Verhältnissen der Gewichtungsfaktoren U und V .

nen jeweils nur die letzte Stunde ausgewertet wurde.

Die Ergebnisse dieser Simulationen sind für das zweite Experiment in den Abbildungen 4.8 und 4.9 zu sehen. In Abbildung 4.8 sind die Blickfrequenzen für fünf ausgewählte Verhältnisse von U/V dargestellt (0, 0.5, 1, 2, ∞). Es lässt sich erkennen, dass je höher das Gewicht U für die Erwartungsparameter ist gegenüber dem Gewicht V für die Wertparameter, desto stärker unterschätzt das Modell die Blickfrequenzen zu den Instrumenten mit niedrigen Ereignisraten. Im Extremfall ($V = 0$) werden die Wertparameter gar nicht berücksichtigt. Die in diesem Fall erzielten Werte sind nahezu identisch mit den Ergebnissen, die mit der multiplikativen Variante erzielt wurden.

Im anderen Extremfall ($U = 0$, $V = 1$) werden ausschließlich die Wertparameter berücksichtigt. Da diese jedoch alle identisch sind, wird die Aufmerksamkeit auf keines der Ziele und damit auch auf keines der Instrumente bevorzugt gerichtet. Es ergeben sich daher Blickfrequenzen, die beinahe identisch mit denen sind, die bei Verwendung des \neg AIE-Agenten erzielt wurden.

Die Datenreihen in Abbildung 4.8 geben eine Schätzung über die Menge an Verhaltensweisen, die das AIE-Modell in der additiven Variante für Senders' Aufgabe potentiell erzeugen kann. Die Ergebnisse, die mit den extremen Verhältnissen von $U/V = 0$ und $U/V = \infty$ erzielt wurden, stellen voraussichtlich auch die extremsten Datenreihen dar. Betrachtet man diese Datenreihen, führt es zu dem Schluss, dass das Modell ein relativ großes Spektrum an Verhalten generieren kann, was problematisch für den Informationsgehalt des AIE⁺-Modells ist.

Bei genauerer Betrachtung lässt sich diese Aussage jedoch relativieren. Zum einen ist das AIE⁺-Modell offenbar nicht in der Lage Blickfrequenzen zu erzeugen, die bei den betrachteten Experimenten zu gegenläufigen Korrelationen führen. Damit ist eine wichtige Klasse an Verhaltensweisen ausgeschlossen. Zum anderen sollte nach Pitt et al. (2006, S.58) ein Modell mit freien Parametern bei Parameteränderungen innerhalb eines sinnvollen Bereichs ein stabiles Verhalten zeigen. Ein sinnvoller Bereich für das Verhältnis U/V beinhaltet sicherlich nicht die Extremwerte 0 und ∞ . Betrachtet man, wie oben beschrieben, die gängige Praxis für die Anwendung des SEEV-Modells, so wird üblicherweise von einer Gleichgewichtung der Erwartungs- und Wertparameter ausgegangen. Man kann also erwarten, dass ein sinnvoller Parameterbereich relativ eng um $U/V = 1$ liegt. Für diesen Bereich zeigt das AIE-Modell tatsächlich ein relativ stabiles Verhalten, da auch die Kurven zu




Abbildung 4.9 – Modellierungsgüte des AIE⁺-Agenten im zweiten Experiment bei unterschiedlichen Verhältnissen der Gewichtungsfaktoren U und V .

$U/V = 1/2$ und $U/V = 2/1$ immer noch eine gute Modellierungsgüte aufweisen (s. Abbildung 4.8).

In Abbildung 4.9 sind die Modellierungsgüten auf Basis der R^2 - und RMSD-Werte für die hier untersuchten Verhältnisse von U/V dargestellt. Im Bereich von 0.2 bis 2.0 ergaben sich mit $R^2 > 0.985$ die höchsten Korrelationen zu den Blickfrequenzen der Versuchspersonen. Die niedrigsten absoluten Abweichungen finden sich im Bereich von 1.0 bis 1.5 mit einer RMSD unter 0.04 Hz. Ein ähnliches Bild zeigt sich für das erste und dritte Experiment (s. Anhang C, Tabelle C.4).

Die beste Modellierung findet sich also tatsächlich im Bereich um $U/V = 1$. Selbst bei Verdopplung eines der Gewichte ist die Modellierungsgüte immer noch sehr gut (s. Abbildung 4.8, $U/V = 1/2$, bzw. $U/V = 2/1$).

Als Fazit lässt sich festhalten, dass das AIE⁺-Modell durch den freien Parameter U/V zwar weniger restriktiv ist als das AIE*-Modell. Mit Blick auf Senders' Aufgabe erscheint es aber dennoch als der bessere Kandidat, da

1. der sinnvolle Parameterraum eingeschränkt ist und die gängige Parameterwahl $U/V = 1$ annähernd das beste Ergebnis erzielt,
2. das Verhalten des AIE*-Modells eine schlechtere Modellierung aufweist als das AIE⁺-Modell und zudem im äußersten Randbereich des vom AIE⁺-Modell potentiell erreichbaren Verhaltens angesiedelt ist.

4.3.3 Simulation mit statischen Erwartungsparametern

Bevor im nächsten Abschnitt die Lernphase des AIE-Modells untersucht wird, werden nun die bisherigen Ergebnisse verglichen mit Ergebnissen, die bei Verwendung von ähnlichen Modellen der Aufmerksamkeitsverteilung zu erwarten sind.

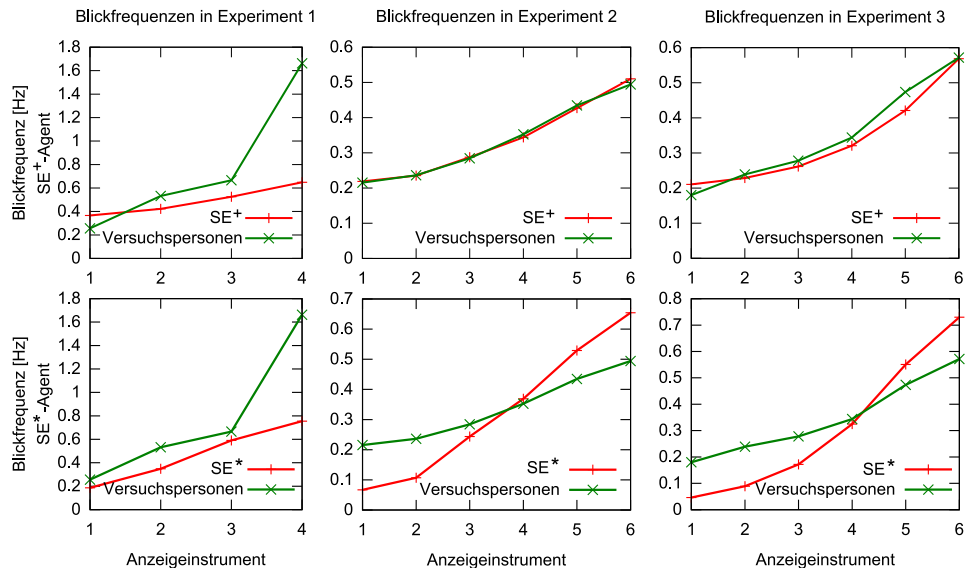
Bisherige Modelle wie die Modelle von Senders (1983), Wickens et al. (2003a) oder Gore et al. (2009), die Ereignisraten als einen Einflussfaktor berücksichtigen, benötigen als Eingabevariablen konkrete Werte der Ereignisraten für jede Informationsquelle. Der zentrale Unterschied zum AIE-Modell besteht vor allem darin, dass das AIE-Modell in der Lage ist, die Ereignisraten dynamisch aus der Simulation abzuleiten, während sie bei bisherigen Modellen statisch vor Beginn der Simulation definiert werden müssen. Bei Szenarien, wie der von Senders untersuchten Aufgabe, in denen die Anzahl der Alarme für jedes Anzeigeelement bekannt sind, ist die a priori Angabe der Ereignisraten ein einfaches und effizientes Vorgehen.

Wie in Abschnitt 3.7.1 beschrieben, wurde bei der Implementierung des AIE-Modells in CASCaS die Option geschaffen, die Erwartungswerte nicht über die Ereignisfunktion zu bestimmen, sondern vom Modellierer statisch vorgeben zu lassen. Die Verwendung dieser Option soll nun mit den Ergebnissen des AIE+- bzw. AIE*-Agenten verglichen werden. Hierzu wurden die Ziele des Agenten in der Aufgabenprozedur mit den Alarmraten der jeweiligen Anzeigeelemente annotiert. Für das erste Experiment wird daher die Aktivierung der Ziele `observe_gauge_1` bis `observe_gauge_4` abgeändert, indem jeweils der `expectancy`-Parameter angegeben wird:

Prozedurabschnitt 4.3 – Zielaktivierung mit statischen Erwartungswerten

```
// This rule fires, if 4 gauges are displayed on the screen
rule=1, name=detect_alarms, type=regular
  Retrieve, screen
  Condition, (screen.number_of_gauges == 4)
  =>
    Goal, name=observe_gauge_1, mode=continuous, value=1.0, expectancy=0.01667
    Goal, name=observe_gauge_2, mode=continuous, value=1.0, expectancy=0.03333
    Goal, name=observe_gauge_3, mode=continuous, value=1.0, expectancy=0.06667
    Goal, name=observe_gauge_4, mode=continuous, value=1.0, expectancy=0.13333
  ;
```

Die hier angegebenen Erwartungswerte entsprechen der tatsächlich auftretenden Anzahl der Alarme pro Sekunde für das jeweilige Anzeigeelement. Für das zweite und dritte Experiment werden die Erwartungswerte entsprechend angegeben. Dieser Agent wurde nun einmal mit der additiven Variante der SEEV-Formel simuliert (SE^+) sowie einmal mit der multiplikativen (SE^*).



	Experiment 1		Experiment 2		Experiment 3	
	R^2	RMSD	R^2	RMSD	R^2	RMSD
SE^+	0.907	1.034 Hz.	0.994	0.020 Hz.	0.971	0.068 Hz.
SE^*	0.806	0.931 Hz.	0.997	0.274 Hz.	0.993	0.288 Hz.

Abbildung 4.10 – Blickfrequenzen des SE^+ -Agenten im Vergleich zu den Blickfrequenzen der Versuchspersonen

Wie bei den in den Abschnitten 4.3.2.1 und 4.3.2.2 beschriebenen Simulationen wurden als Gewichte $U = 1$ und $V = 1$ verwendet. Für jede Variante wurden zehn Simulationsläufe über je drei Stunden durchgeführt. Da bei fester Vorgabe der Erwartungsparameter keine Lerneffekte auftreten, ist auch keine Lernphase notwendig. Daher wurden die Daten der gesamten Simulation für die Auswertung herangezogen.

In den oberen Diagrammen in Abbildung 4.10 sind die Blickfrequenzen bei Verwendung des SE⁺-Agenten zu sehen. Die Datenpunkte sind beinahe identisch mit denen, die bei Verwendung des AIE⁺-Agenten erzielt wurden (vgl. Abbildung 4.5). Analog dazu erzeugt der SE^{*}-Agent (untere Diagramme in Abbildung 4.10) ähnliche Blickfrequenzen wie bei Verwendung des AIE^{*}-Agenten. Dabei wurden die Blickfrequenzen zu den Anzeigeelementen mit niedriger Alarmrate unterschätzt und zu denen mit hohen Alarmraten überschätzt.

Die Ähnlichkeit der Ergebnisse zwischen den AIE-Varianten und den SE-Varianten spiegelt sich auch in ähnlich guten Modellanpassungsgüten wider. Die guten Ergebnisse, die mit den statischen Erwartungsparametern erzielt wurden, deuten darauf hin, dass die dynamische Ermittlung der Ereignishäufigkeiten über die Ereignisfunktionen unter Umständen gar nicht nötig ist, wenn die Ereignishäufigkeiten bekannt sind. Die Verwendung der statischen Werte hat den Vorteil, dass die Lernphase für die Ereignisfunktionen entfällt, die andernfalls einen zusätzlichen Arbeitsschritt darstellt. Im nächsten Kapitel wird anhand eines Fahrermodells ein Anwendungsfall präsentiert, bei dem die Ereignishäufigkeiten nicht für alle Informationsquellen bekannt sind.

4.3.4 Lernphase

Die automatische Bestimmung der Ereignisraten erfordert einen zusätzlichen Arbeitsschritt, da zu Beginn der Simulation erst einige Ereignisse auftreten müssen, bevor das AIE-Modell stabile Ereignisfunktion ermittelt hat und eine vernünftige Abschätzung zu den Erwartungswerten geben kann. In diesem Abschnitt soll daher die Lernphase des AIE-Modells betrachtet werden. Dabei sollen die in Abschnitt 3.4 genannten Aspekte bezüglich der Konvergenz der Ereignisfunktionen untersucht werden.

Es wird untersucht, wie sich die Ereignisfunktionen während der Lernphase entwickeln, und ab wann von stabilen Ereignisfunktionen ausgegangen werden kann. Zu diesem Zweck wurde ein Agent für längere Zeiträume simuliert. Als Konfiguration wurde der AIE⁺-Agent, wie in Abschnitt 4.3.2.1 beschrieben, mit $U = 1$ und $V = 1$ gewählt.

Der Agent wurde nun 20 mal für jeweils 9 Simulationsstunden simuliert. Alle fünf Minuten wurde der aktuelle Zustand der Ereignisfunktionen aufgezeichnet. Wenn die Ereignisfunktionen immer gegen die gleiche Grenzfunktion konvergieren (Abschnitt 3.4, Aspekt 1), dann sollten sich die Ereignisfunktionen der Simulationsläufe mit voranschreitender Simulationszeit immer weniger unterscheiden und die Ereignisfunktionen der 20 Simulationsläufe sollten sich nach ausreichend langer Simulationszeit immer im gleichen Zustand stabilisieren.

Um die Unterschiedlichkeit der Ereignisfunktionen zu bestimmen, wurde das Differenzmaß V aus Kuiper's Test verwendet. Es ermittelt die Ähnlichkeit zweier kumulativer Häufigkeitsverteilungen H_1 und H_2 wie folgt (nach Press et al., 1992):

$$V_K = \max_{0 < \Delta t < \infty} (H_1(\Delta t) - H_2(\Delta t)) + \max_{0 < \Delta t < \infty} (H_2(\Delta t) - H_1(\Delta t))$$




Abbildung 4.11 – Durchschnittliche Ähnlichkeit der Ereignisfunktionen aus 20 Simulationsläufen, ermittelt über Kuipers V_K -Maß und aufgetragen über die Simulationszeit. Rechts: Logarithmische Skalierung deutet Kurvenverlauf der Form $a \cdot x^{-b}$ an. Diese Funktion ist links an alle Datenreihen angepasst eingezeichnet (dickere Linie).

Für Kuiper's Differenzmaß wird in dieser Arbeit das Symbol V_K verwendet, um eine Verwechslung mit dem Gewichtungsfaktor V des AIE-Modells zu vermeiden. Nach jedem fünfminütigen Simulationsschritt wurden für jedes mögliche Paar aus jeweils zwei der 20 Simulationsläufe die V_K -Werte für die Ereignisfunktionen aller Ziele gebildet. Bei n Simulationsläufen ergeben sich $\sum_{i=1}^{n-1} i$ mögliche Paarungen. In diesem Fall ergeben sich bei 20 Simulationsläufe für jede Ereignisfunktion zu jedem Simulationsschritt 190 Differenzwerte. Erwartet wird, dass sich die Ereignisfunktionen der unterschiedlichen Simulationsläufe mit voranschreitender Zeit immer mehr ähneln. Daher sollten sich die durchschnittlichen V_K -Werte mit der Zeit verringern und gegen null laufen. Dies ist in Abbildung 4.11 (links) dargestellt. Aufgetragen sind dort die durchschnittlichen V_K -Werte für das zweite Experiment mit sechs Anzeigegeräten (s. S. 93). An den Kurvenverläufen lässt sich die Konvergenzgeschwindigkeit der Ereignisfunktionen ablesen (Abschnitt 3.4, Aspekt 2). Ähnliche Kurvenverläufe zeigen sich auch für das erste und dritte Experiment. Diese sind hier jedoch nicht dargestellt. Es ist gut zu erkennen, dass zu Beginn größere Differenzen zwischen den Ereignisfunktionen bestehen. Diese reduzieren sich anfangs sehr schnell. Die Geschwindigkeit dieser Reduktion nimmt jedoch immer weiter ab.

Trägt man die Daten in einem logarithmisch skaliertem Koordinatensystem auf, so ergibt sich ein Bild mit sechs linear verlaufenden Kurven (Abbildung 4.11, rechts). Ein solcher Kurvenverlauf lässt sich gut über Potenzfunktionen der Form $a \cdot x^{-b}$ beschreiben. Es entspricht zudem in der Art dem Kurvenverlauf, der zu erwarten ist, wenn keine Rückkopplungen beim Lernen der Ereignisfunktionen auftreten und diese somit gegen eine Grenzfunktion konvergieren (s. Abschnitt 3.4). Zudem verlaufen die Kurven in der logarithmischen Darstellung annähernd parallel. Dies deutet auf identische Exponenten b hin. Auch dies wurde in Abschnitt 3.4 erwartet, da für b bei allen Ereignisfunktionen ein Wert von ungefähr $\frac{1}{2}$ vermutet wird. Dieser Parameter beschreibt maßgeblich die Dynamik des Lernprozesses. Je größer b ist, desto schneller konvergieren die Differenzwerte gegen null und damit die Ereignisfunktionen gegen eine gemeinsame Grenzfunktion.

Für jeden Datensatz an Differenzmaßen, der sich für die Ereignisfunktion eines der sechs Ziele `observe_gauge_1` bis `observe_gauge_6` ergeben hat, wurde nun eine ent-

sprechende Funktion über die [Methode der kleinsten Quadrate](#) geschätzt mit der Einschränkung, dass b bei allen sechs Funktionen identisch ist. Dabei ergaben sich die Parameter

$$\begin{aligned} a_{\text{observe_gauge_1}} &= 0.060, & a_{\text{observe_gauge_2}} &= 0.090, \\ a_{\text{observe_gauge_3}} &= 0.204, & a_{\text{observe_gauge_4}} &= 0.302, \\ a_{\text{observe_gauge_5}} &= 0.443, & a_{\text{observe_gauge_6}} &= 0.552, \\ b &= 0.440. \end{aligned}$$

Im linken Diagramm von [Abbildung 4.11](#) sind die resultierenden Funktionen mit etwas dickeren Linien zusammen mit den während der Simulation gemessenen Werten aufgetragen.

Für Experiment 1 und 3 ergaben sich mit $b = 0.465$ bzw. $b = 0.415$ ähnliche Werte zur geschätzten Lerngeschwindigkeit. Sie sind etwas geringer als der erwartete Wert von $\frac{1}{2}$. An dieser Stelle wird vermutet, dass dies hauptsächlich auf die Rückkopplungen im Lernprozess zurückzuführen ist. Eine weitere mögliche Quelle für die Abweichungen liegt in der Bestimmung der Konvergenzgeschwindigkeit über die V_K -Werte. Der erwartete Wert von $\frac{1}{2}$ bezieht sich auf die punktweise Konvergenzgeschwindigkeit einer Verteilungsfunktion. Kuiper's Differenzmaß wird jedoch über die gesamte Verteilungsfunktionen bestimmt und bezieht sich daher auf die gleichmäßige Konvergenz der Verteilungsfunktion. Zudem wird hier nicht direkt die Differenz zu der tatsächlich zu erwartenden Verteilungsfunktion verwendet, da diese nicht bekannt ist. Stattdessen wird sie mittels der durchschnittlichen Differenz der in den 20 Simulationsläufen erzeugten Verteilungsfunktionen geschätzt.

Die gleiche Untersuchung wurde auch für den AIE*-Agenten durchgeführt. Es ergab sich ein ähnlicher Verlauf der Lernkurven, jedoch war die Lerngeschwindigkeit mit $b = 0.359$ deutlich geringer als beim AIE⁺-Agenten. Dies deutet darauf hin, dass die Rückkopplungen bei diesem Agenten einen wesentlich stärkeren Einfluss auf das Lernen der Ereignisfunktionen haben. Dieser Agent benötigt daher eine etwas längere Trainingsphase.

Geht man von Kurvenverläufen der Form $f(x) = a \cdot x^{-b}$ aus, dann lässt sich kein klarer Zeitpunkt angeben, ab dem man den Lernprozess für die Ereignisfunktionen als beendet ansehen kann ([Abschnitt 3.4](#), [Aspekt 3](#)), da die Ereignisfunktionen kontinuierlich immer mehr den Grenzfunktionen ähneln, wenn auch immer langsamer. Letztendlich ist beim Lernprozess jedoch nicht von Interesse, wie sich die Ereignisfunktionen entwickeln, sondern wie dies die Aufmerksamkeitsverteilung beeinflusst. In [Abbildung 4.12](#) ist dargestellt, wie sich das Blickverhalten des AIE⁺-Agenten im zweiten Experiment über die Zeit entwickelt. Abgebildet sind die Blickfrequenzen (oben links), Blickdauern (oben rechts) und prozentualen Blickverweilzeiten (unten links). Die aufgetragenen Werte wurden für Intervalle von jeweils fünf Minuten bestimmt und stellen die gemittelten Werte über alle 20 Simulationsläufe dar.

Die Kurvenverläufe ähneln den Verläufen, die das Konvergenzverhalten der Ereignisfunktionen beschreiben (vgl. [Abbildung 4.11](#)). Allerdings streben sie nicht gegen einen Grenzwert von null, sondern gegen den für das jeweilige Anzeigensinstrument erwarteten Wert der Blickfrequenz bzw. Blickdauer oder PDT. Es lassen sich daher gut Funktionen der Form $f(t) = a \cdot x^b + c$ an die Kurven anpassen. Hierbei bezeichnet c den Erwartungswert gegen den die Funktion konvergiert.

Wie auch bei den Konvergenzkurven der Ereignisfunktionen deuten die Kurvenverläufe darauf hin, dass die Rate (b), mit der sich die Lerngeschwindigkeit ändert, für alle Instrumente gleich ist. Es wurden nun Funktionen in der beschriebenen Form an die Daten angepasst. Bei der Anpassung wurden die Parameter a und c individuell

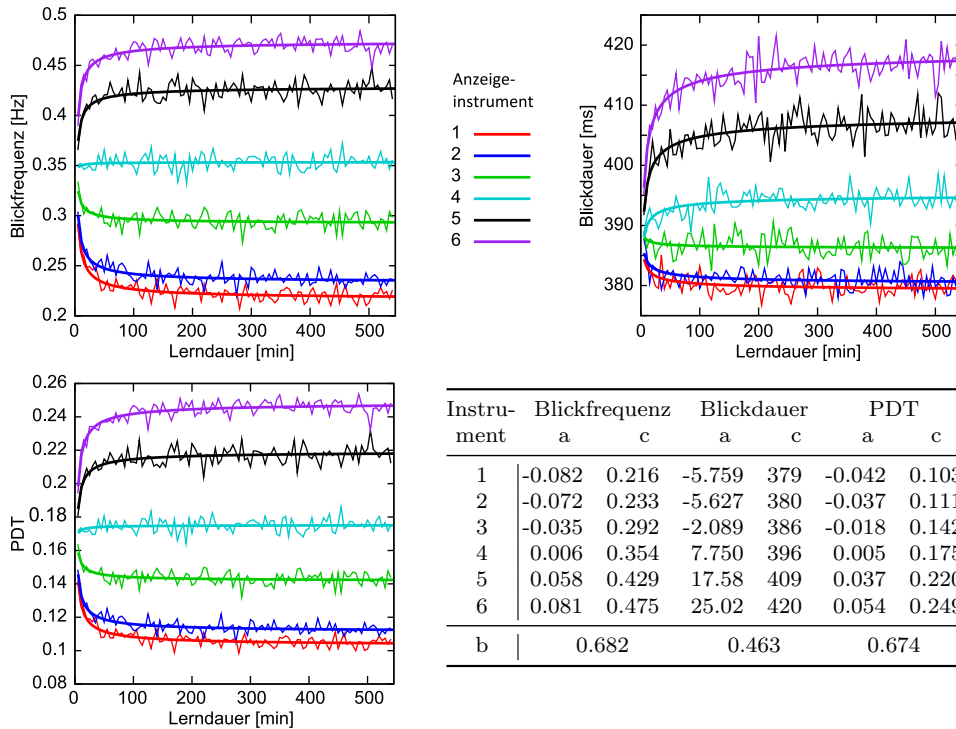


Abbildung 4.12 – Effekt der Lernphase auf die durchschnittliche Blickfrequenz (oben links), die durchschnittliche Blickdauer (oben rechts) und die prozentuale Blickverweilzeit (unten links). Für die Messwerte sind Approximationen der Form $a \cdot x^b + c$ eingezeichnet mit den Parametern aus der Tabelle unten rechts.

für jede Datenreihe bestimmt, während für den Exponenten b wieder die Beschränkung galt, dass er für alle Datenreihen identisch sein soll. In Abbildung 4.12 sind die ermittelten Funktionen als dickere Linie zusammen mit den Datenreihen (dünne Linien) eingezeichnet. Die Parameter der Funktionen sind unten rechts aufgeführt. Mit den berechneten Erwartungswerten (c) lassen sich die in Abschnitt 4.3.2 beschriebenen Ergebnisse nun bewerten, bezüglich der Frage, wie sehr sich die Ergebnisse durch den Lernprozess ändern würden, wenn man längere Simulationen durchgeführt hätte. Es zeigt sich, dass die Blickfrequenzen, die mit dem AIE⁺-Agenten ermittelt wurden, im Durchschnitt lediglich um 0.005 Hz pro Informationsquelle von den hier ermittelten Erwartungswerten abweichen. Dies entspricht einer Abweichung von etwa 1.6 Prozent. Bei der multiplikativen Variante ist die Abweichung mit 0.033 Hz deutlich größer. Die größeren Abweichungen lassen sich aber auch erahnen, wenn man die Exponenten der Lernkurven für die multiplikative Variante betrachtet. Für das zweite Experiment ergibt sich beim AIE^{*}-Agenten für die Blickfrequenz $b = 0.432$, für die Blickdauer $b = 0.109$ und für die PDT $b = 0.450$. Diese Werte sind deutlich geringer als bei der additiven Variante, was zu einer geringeren Lerngeschwindigkeit führt. Dieser Effekt zeigt sich in ähnlicher Größenordnung auch für das erste und dritte Experiment. Detaillierte Werte zu Experiment 1 und 3 finden sich tabellarisch in Anhang C (Tabelle C.5).

Mit Blick auf die langsamere Lerngeschwindigkeit könnte man vermuten, dass eine zu kurze Lernphase eine Ursache für die schlechtere Modellanpassung der multiplikativen Variante an die Experimentaldaten ist (vgl. Abschnitt 4.3.2). Tatsächlich




Abbildung 4.13 – Die punktwise gemittelten Ereignisfunktionen aus 20 Simulationenläufen nach jeweils neun Stunden Simulationszeit. Dicke Linien: Ereignisfunktionen des AIE⁺-Agenten. Dünne Linien: Ereignisfunktionen des AIE^{*}-Agenten.

zeigt sich jedoch der gegenteilige Effekt. Die hier berechneten Erwartungswerte weichen sogar noch stärker vom Blickverhalten der Versuchspersonen ab.

In **Abbildung 4.13** sind für das zweite Experiment die durchschnittlichen Ereignisfunktionen abgebildet, die schließlich für die 20 Simulationenläufe nach einer Simulationszeit von jeweils neun Stunden erzielt wurden. Die Ereignisfunktionen des AIE⁺-Agenten sind durch dicke Linien dargestellt und die des AIE^{*}-Agenten durch dünne Linien. Die Ereignisfunktionen ähneln sich größtenteils. Es ist dennoch gut zu erkennen, dass die Kurvenverläufe für die Anzeigegeräte mit hohen Alarmraten für den AIE^{*}-Agenten etwas höher ansteigen als beim AIE⁺-Agenten, wohingegen die Kurvenverläufe für die Instrumente mit niedriger Alarmrate niedriger ausfallen.

Dies spiegelt sich auch in den Blickfrequenzen wider (s. **Abbildung 4.5** und **4.7**, S. 99 und 101). Durch die sehr niedrige Blickfrequenz des AIE^{*}-Agenten zu den Instrumenten mit niedriger Alarmrate werden einige Alarme übersehen und somit fließen weniger Ereignisse in die Ereignisfunktionen ein. Der umgekehrte Effekt lässt sich bei den Instrumenten mit hohen Alarmraten beobachten. Die Blickfrequenz des AIE^{*}-Agenten zu den Instrumenten mit hoher Alarmrate ist zwar nicht höher als beim AIE⁺-Agenten, aber die Blickdauern sind länger, da eine weitere Erhöhung der Auswahlwahrscheinlichkeit dazu führt, dass sich die Wahrscheinlichkeit erhöht, dass ein solches Ziel mehrmals hintereinander ausgewählt wird. Das jedoch erhöht nicht die Blickfrequenz, sondern die Blickdauer.

4.3.5 Untersuchung der Verhaltensvariabilität

Das AIE-Modell wählt während der Simulation die Ziele des Agenten aus. Dies geschieht nicht-deterministisch. Die Auswahlwahrscheinlichkeit richtet sich nach der Größe der Erwartungs- und Wertparameter. Das bedeutet, dass sich das Verhalten eines Agenten bei gleicher Ausgangslage für zwei verschiedene Simulationenläufe unterscheidet.

Diese Variabilität im Verhalten ist durchaus nicht unerwünscht, da auch die Versuchspersonen gewisse Verhaltensvariabilitäten aufweisen. Ist diese beim Agenten jedoch stark ausgeprägt, so kann es prinzipiell dazu führen, dass der Agent eine

größere Varianz im Verhalten zeigt, als die Varianz, die bei den Versuchspersonen beobachtet wurde. In diesem Fall wird extremes Verhalten vom Agenten häufiger erzeugt, als man es in der Realität beobachten würde. Betrachtet man Modelle, die ansonsten eine gute Anpassung an die tatsächlich gemessenen Daten erzielen, deren Varianz aber von der tatsächlich gemessenen Varianz abweicht, so sind tendenziell die Modelle zu bevorzugen, die eine geringere Varianz als die tatsächlich gemessene aufweisen, da sie nicht dazu neigen extremes und unter Umständen unrealistisches Verhalten zu generieren.

In diesem Abschnitt wird daher ein Blick auf die Varianz im Blickverhalten geworfen. Da die Anzahl der Versuchspersonen ($n=5$) in Senders Experimenten gering war, kann nur eine grobe Abschätzung gemacht werden. Um dem entgegenzuwirken, werden die Daten aus den Experimenten 2, 4 und 5 aggregiert betrachtet. Die Versuchsbedingungen dieser Experimente unterscheiden sich nur geringfügig. Die Signalbandbreiten sind bei allen Anzeigeelementen identisch. Zudem ähneln sich die ermittelten durchschnittlichen Blickfrequenzen für die einzelnen Instrumente bei allen drei Experimenten sehr stark. In Anhang C sind die Blickfrequenzen aus Senders' Studien für alle Experimente aufgelistet (Tabelle C.1).

Für jedes Anzeigeelement wurde die durchschnittliche Varianz der Blickfrequenz über die drei Experimente gebildet. Nun kann man vermuten, dass bei den Anzeigeelementen mit niedriger Signalbandbreite, bei denen dementsprechend auch eine niedrige Blickfrequenz gemessen wurde, die Varianz geringer ist als bei den Instrumenten mit hoher Bandbreite, da die niedrige Blickfrequenz auch den Spielraum für die Varianz einschränkt. Es zeigte sich jedoch kein Zusammenhang zwischen der Signalbandbreite der Instrumente und der Größe der beobachteten Varianz ($r = 0.12$). Für die folgende Betrachtung wird daher nicht zwischen den einzelnen Anzeigeelementen differenziert. Die mittlere Standardabweichung bei den Blickfrequenzen der Versuchspersonen beträgt 0.06 Hz.

Um diese nun mit dem durch das AIE-Modell erzeugtem Blickverhalten zu vergleichen, wurden die Ergebnisse betrachtet, die bei Verwendung des AIE⁺-Modells mit $U=1$ und $V=1$ erzielt wurden (vgl. Abschnitt 4.3.2.1). Es wurden wiederum nur die Ergebnisse betrachtet, die nach einer Lernphase von zwei Stunden erzielt wurden. Die Blickfrequenzen der Versuchspersonen wurden über einen Zeitraum von elf Minuten aggregiert. Für das Modell wurden die Blickfrequenzen nun ebenfalls über Intervalle von elf Minuten bestimmt. Die Varianz der Blickfrequenzen ist mit 0.03 Hz nur etwa halb so groß, wie die bei den Versuchspersonen beobachtete. Das Modell scheint daher zwar gut in der Lage zu sein, die durchschnittlichen Blickfrequenzen zu schätzen, jedoch spiegeln die Simulationen die Verhaltensvariabilität der Versuchspersonen nur moderat wider.

4.4 Zusammenfassung

In diesem Kapitel wurde das AIE-Modell anhand einer sehr einfachen Laboraufgabe evaluiert. Dabei wurden verschiedene Konfigurationsmöglichkeiten des Agenten betrachtet, der mit dem Aufgabeninterface interagiert. Die Untersuchung führte u. a. zu folgenden Ergebnissen:

1. Die Verwendung des AIE-Modells verringert den Unterschied zwischen dem Blickverhalten der Versuchspersonen und dem des in CASCaS instanziierten Agenten erheblich.
2. Das AIE-Modell erzielt bei Verwendung der additiven SEEV-Formulierung

deutlich bessere Ergebnisse bezüglich der Blickfrequenzen als bei der multiplikativen Variante. Bei Betrachtung der Transitionswahrscheinlichkeiten lässt sich allerdings keine der beiden Varianten klar präferieren, da beide Defizite im Vergleich zu den Versuchspersonen aufweisen. Insbesondere werden Transitionen zwischen zwei Instrumenten mit niedrigeren **Ereignisraten** überschätzt.

3. Bei einer Agentenkonfiguration ähnlich wie in **MIDAS**, bei der statische Erwartungsparameter verwendet werden (SE-Agenten), werden ähnlich gute Ergebnisse für die Blickfrequenzen erzielt wie bei Verwendung des AIE-Modells.
4. Die Lerngeschwindigkeit des AIE-Modells lässt sich gut über eine Potenzfunktion abschätzen. Dabei zeigte sich eine höhere Lerngeschwindigkeit bei Verwendung der additiven SEEV-Formulierung im Vergleich zur multiplikativen Formulierung.
5. Das AIE-Modell erzeugt eine Verhaltensvariabilität, die geringer ist, als die interindividuelle Variabilität der Versuchspersonen.

Es gilt jedoch zu beachten, dass die erzielten Ergebnisse sich nur auf die hier untersuchte, sehr einfache Überwachungsaufgabe beziehen. Und selbst für diese einfache Aufgabe wurden nicht alle Einflussfaktoren berücksichtigt.

Bohnen et al. (1996) zeigten, dass für die hier untersuchte Aufgabe die Position und Richtung des Zeigers während der letzten Beobachtung eines Instruments einen erheblichen Einfluss auf die Länge der Zeitspanne bis zur nächsten Beobachtung desselben Instruments haben. Etwas allgemeiner betrachtet nutzen die Versuchspersonen Hinweise aus dem Kontext der aktuellen Situation, um das Auftreten zukünftiger **Ereignisse** vorherzusagen. **Wickens und McCarley (2008, S.48)** bezeichnen dies als kontextbasierten Einfluss auf die Aufmerksamkeit und ordnen diesen Einfluss der Erwartungskomponente des SEEV-Modells zu. Die Integration eines geeigneten Modells zur Berücksichtigung der kontextbasierten Erwartung in das AIE-Modell könnte eventuell helfen, um die moderaten Ergebnisse, die bezüglich der Transitionswahrscheinlichkeiten erzielt wurden, zu verbessern.

Senders hat mit maximal sechs Instrumenten nur eine sehr geringe Anzahl an Instrumenten verwendet. In industriellen Großanlagen werden wesentlich mehr Werte überwacht. Diese haben jedoch auch häufig eine wesentlich geringere Informationsrate. Die Wahl von sechs Instrumenten ist sicherlich auf die damals eingeschränkten Möglichkeiten zur Blickverfolgung zurückzuführen. Mit heutigen Eyetracking-Systemen ist es jedoch vergleichsweise einfach, die Blickbewegungen auch bei einer sehr großen Anzahl an Anzeigeelementen zu untersuchen. Für zukünftige Arbeiten wäre es daher interessant, zu überprüfen, ob sich die vom AIE-Modell vorhergesagten Muster im Blickverhalten auch in komplexeren Situationen mit wesentlich mehr Anzeigeelementen wiederfinden.

Im nächsten Kapitel wird das Modell nun anhand einer realistischeren Aufgabe untersucht.

Kapitel 5

Evaluation II: Fahrstudie

Auf kurvenreichen Straßen besteht eine der Hauptaufgaben des Fahrers darin, das Fahrzeug innerhalb der eigenen Fahrspur zu führen (**Lateralkontrolle**). Hierzu benötigt der Fahrer ständig Informationen über die aktuelle Position des Fahrzeugs in der Spur und über den weiteren Verlauf der Straße (**Land und Horwood, 1995; Donges, 1978**). Allerdings sind für den Fahrer auch andere Informationsquellen von Interesse, auf die er seine Aufmerksamkeit richtet, wie der umgebende Verkehr, Anzeigen im Fahrzeug, Geschehnisse neben dem Fahrbahnrand oder auch Mitfahrer. Das AIE-Modell wurde mit der Intention entwickelt, die Aufmerksamkeitsverteilung von Autofahrern zu simulieren. In diesem Kapitel wird daher das AIE-Modell anhand einer Fahrstudie in einem geeigneten Szenario evaluiert. In diesem Szenario mussten die Versuchsfahrer ihre Aufmerksamkeit zwischen der Fahraufgabe und einer Nebenaufgabe aufteilen.

Die grundlegende Struktur des Kapitels ist aufgebaut wie bei der ersten Evaluation zu Senders Monitoring-Aufgabe. Es wird zuerst ein Experiment beschrieben, das durchgeführt wurde, um Vergleichsdaten von menschlichen Autofahrern zu erhalten. Anschließend wird ein Agentenmodell vorgestellt, das die Aufgaben der Versuchspersonen übernimmt. In diesem Fall handelt es sich also um ein Fahrermodell. Schließlich wird das Fahrermodell im untersuchten Szenario simuliert und das Verhalten des Fahrermodells mit dem Verhalten der Versuchspersonen verglichen.

Im Detail ist die Struktur jedoch etwas komplexer als bei der ersten Evaluation. In **Abbildung 5.1** ist daher eine Übersicht über den Aufbau des Kapitels mit den wichtigsten Abhängigkeiten zwischen den einzelnen Abschnitten dargestellt.

Anders als in der ersten Evaluation wurde für die experimentellen Daten nicht auf Daten aus der Literatur zurückgegriffen, sondern es wurde eine Fahrstudie durchgeführt, die speziell für die Analyse der Aufmerksamkeitsverteilung der Versuchsfahrer konzipiert wurde. In **Abschnitt 5.1** werden die Experimenthypothesen bezüglich der Aufmerksamkeitsverteilung der Versuchsfahrer beschrieben. Anschließend wird ein Versuchsaufbau entworfen, mit dem sich die Hypothesen prüfen lassen (**Abschnitt 5.2**).

Um einen Vergleich zu dem in der Literatur oftmals verwendeten SEEV-Modell zu ermöglichen, wird in **Abschnitt 5.3** das SEEV-Modell auf das Experimentenszenario angewendet. Dabei wird das SEEV-Modell auf die gleiche Art angewendet, wie es

auch von Horrey et al. (2006) in einer sehr ähnlichen Fahrstudie genutzt wurde. Als Resultat ergeben sich Vorhersagen zu den **prozentualen Blickverweilzeiten (PDTs)** der Versuchsfahrer. Im Gegensatz zum SEEV-Modell wird das AIE-Modell vor der Experimentdurchführung noch nicht verwendet, um Vorhersagen zu generieren, da vor der Experimentdurchführung noch kein ausreichend parametrisiertes Fahrermodell für das Versuchsszenario vorlag. Teile der Versuchsdaten werden genutzt, um eben diese Parametrisierung durchzuführen (Abschnitt 5.7).

Die Aufbereitung der Versuchsdaten wird kurz in Abschnitt 5.4 erläutert. Es wird dabei unterschieden zwischen Blickdaten (Blicke und Transitionen), Fahrverhaltensdaten (Längs- und Querbewegungen des Fahrzeugs) und Daten zur Nebenaufgabe (Reaktionszeiten und Interaktionsfehler). Die Auswertung dieser Daten wird in Abschnitt 5.5 beschrieben. Dabei werden drei unterschiedliche Analysen vorgenommen. Anhand der Blickdaten werden die Experimenthypothesen überprüft (Abschnitt 5.5.1). Zudem werden die Blickdaten genutzt, um die Korrelation zwischen den Vorhersagen des SEEV-Modells und dem Blickverhalten der Versuchspersonen zu bestimmen (Abschnitt 5.5.3). Im Gegensatz zum SEEV-Modell lassen sich mit dem AIE-Modell neben den PDTs noch weitere Vorhersagen zum Blickverhalten machen, da das AIE-Modell innerhalb einer kognitiven Architektur integriert ist, mit der sich vollständige Blicksequenzen simulieren lassen. Durch die Integration in einer kognitiven Architektur lässt sich zudem auch die Interaktion zwischen Aufmerksamkeitsverteilung und Aufgabenbearbeitung simulieren. In einem weiteren Schritt wird daher in Abschnitt 5.5.2 eine explorative Analyse der Daten zum Fahrverhalten und zur Bearbeitung der Nebenaufgabe durchgeführt. Potentielle Effekte, die sich bei dieser Analyse zeigen, sollten auch vom Fahrermodell wiedergegeben werden. Dies wird später bei der Analyse der Simulationsergebnisse in Abschnitt 5.8 überprüft. Dabei wird insbesondere untersucht, inwieweit das AIE-Modell das Fahrverhalten bzw. die Bearbeitung der Nebenaufgabe beeinflusst.

Nach der Analyse der Experimentdaten wird das Fahrermodell erläutert. Die generelle Struktur des Fahrermodells mit einer Beschreibung der einzelnen Unterauf-

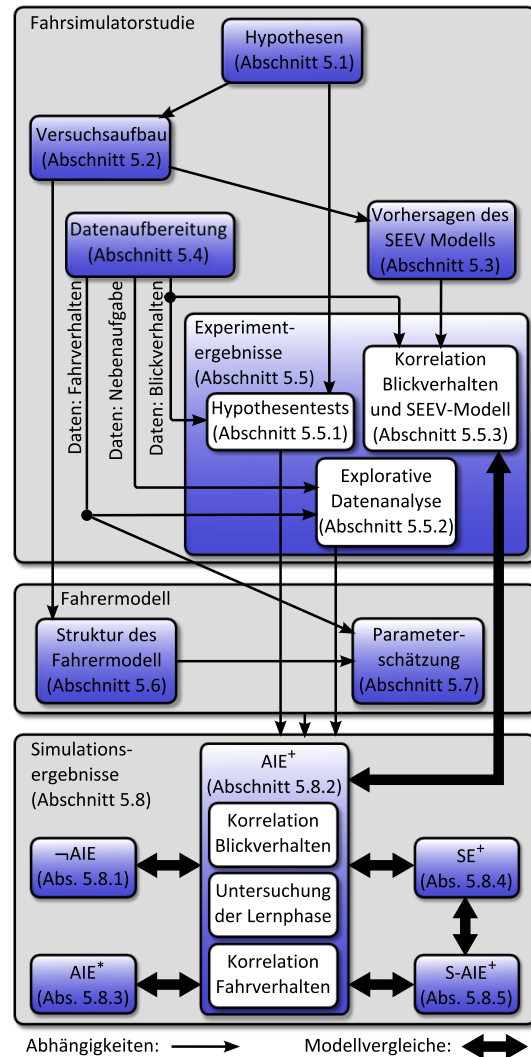


Abbildung 5.1 – Struktur diese Kapitels

gaben wird in Abschnitt 5.6 wiedergegeben. Die Fahraufgabe ist im Fahrermodell unterteilt in **Lateral-** und **Longitudinalkontrolle**. In Abschnitt 5.7 wird beschrieben, wie einige freie Parameter für diese Kontrollaufgaben an das Szenario angepasst wurden. Dies geschah auf Basis der Fahrverhaltensdaten der Versuchspersonen. In Abschnitt 5.8 werden schließlich die Simulationsergebnisse des Fahrermodells präsentiert. Wie bereits bei der ersten Evaluation in Kapitel 4 werden die Ergebnisse verschiedener Varianten des AIE-Modells verglichen. Es wurden Simulationen durchgeführt

- ohne AIE-Modell (\neg AIE),
- mit additiver Variante des AIE-Modells (AIE⁺),
- mit multiplikativer Variante des AIE-Modells (AIE*),
- mit statischen Erwartungsparametern (SE⁺) und
- mit einer vereinfachten Variante des AIE-Modells (S-AIE⁺).

Es findet ein weiterer Vergleich zwischen den vom AIE-Modell erzeugten PDTs und den Vorhersagen des SEEV-Modells statt. Zudem wird wie bereits bei der Evaluation zu Senders Aufgabe das Lernverhalten des AIE-Modells anhand der AIE⁺-Variante untersucht. Auf eine Sensitivitätsanalyse wurde aufgrund des sehr hohen Simulationsaufwandes jedoch verzichtet.

Abschließend werden die Ergebnisse dieser Evaluation in Abschnitt 5.9 zusammengefasst.

Die Ergebnisse werden in diesem Kapitel in Form von Diagrammen und wichtigen Kennzahlen präsentiert. In Anhang C der Arbeit sind die Datenbasen dieser Diagramme in tabellarischer Form aufgelistet soweit es vom Umfang der Daten her sinnvoll erschien. Zudem finden sich in Anhang B die Formulare und Instruktionen für die Versuchspersonen, weiterführende Angaben zu den Versuchspersonen, die Randomisierung der Versuchsbedingungen sowie die vollständigen Ergebnisse der Varianzanalysen.

5.1 Hypothesen

Ziel des Fahrsimulatorexperiments ist es, die beiden Einflussfaktoren, die das AIE-Modell berücksichtigt (**Ereignisraten** und **Aufgabenprioritäten**), in einer realistischen Fahrsimulation kontrolliert zu verändern, und den Effekt zu bestimmen, den diese Faktoren auf die Aufmerksamkeitsverteilung der Versuchsfahrer haben. Zu diesem Zweck wurde ein Simulationsszenario entworfen, in dem die Versuchsfahrer ihre Aufmerksamkeit kontinuierlich auf drei Aufgaben richten müssen:

- das Führen des Fahrzeugs mittig innerhalb der Fahrspur (Lateralkontrolle),
- das Halten einer konstanten Geschwindigkeit von 100 km/h (Longitudinalkontrolle) und
- das Bearbeiten einer wiederkehrenden Nebenaufgabe.

Es wurden die **Ereignisraten** für die Lateralkontrolle und die Nebenaufgabe sowie die **Prioritäten** für alle drei Aufgaben variiert. Hierzu wurde eine kurvenreiche Strecke ohne vorausfahrenden Verkehr als Szenario gewählt. Unterschiedliche Ereignisraten für die **Lateralkontrolle** wurden durch verschieden starke Krümmungen

der Straße realisiert. Die Nebenaufgabe wurde auf einer Anzeige in der Mittelkonsole des Fahrzeugs angezeigt. Bei dieser Aufgabe wurde die Ereignisrate durch eine unterschiedlich hohe Wiederholungsrate variiert. Die Aufgabenprioritäten wurden durch Instruktionen gezielt manipuliert.

Da vor Beginn des Experiments noch kein Fahrermodell vorlag, konnten keine Vorhersagen durch Simulationen mithilfe des AIE-Modells erzeugt werden. Allerdings lassen sich einige Hypothesen zum Blickverhalten auf der theoretischen Basis des AIE-Modells aufstellen. Beim AIE-Modell wird davon ausgegangen, dass sich die Aufmerksamkeitsverteilung zu Aufgaben erhöht, die eine erhöhte Ereignisrate oder eine erhöhte Priorität aufweisen. Dies ist eine Grundlage für die Hypothesen in diesem Experiment.

Die Aufmerksamkeitsverteilung wird über die Blickverteilung der Versuchspersonen bestimmt. Dabei wird davon ausgegangen, dass die Versuchspersonen für jede der drei Aufgaben jeweils nur eine Informationsquelle verwenden.

1. Die vorausliegende **Straße** ist relevant für die Lateralkontrolle.
2. Die **Geschwindigkeitsanzeige** ist relevant für die Longitudinalkontrolle.
3. Die Anzeige in der **Mittelkonsole** ist relevant für die Nebenaufgabe.

Informationen zur aktuellen Geschwindigkeit lassen sich auch über den optischen Fluss beim Blick auf die Straße gewinnen. In Simulatorstudien zeigten [Pretto und Chatziastros \(2006\)](#) sowie [Durkee und Ward \(2011\)](#), dass dabei die geschätzte Geschwindigkeit typischerweise um etwa 20 km/h von der tatsächlichen Geschwindigkeit abweicht. Aufgrund der hohen Schätzungenauigkeit und der Instruktion der Versuchspersonen, möglichst präzise eine Zielgeschwindigkeit von 100 km/h einzuhalten (s. Abschnitt 5.2.5), wird in der vorliegenden Arbeit davon ausgegangen, dass der optische Fluss keine hilfreichen Informationen zur Geschwindigkeitskontrolle liefert. Daher ist die Geschwindigkeitsanzeige hier die einzige relevante Informationsquelle für die Longitudinalkontrolle.

Allerdings kann auch die Streckenkrümmung einen Einfluss auf die Geschwindigkeitskontrolle haben, da einige Autofahrer ihre Geschwindigkeit in scharfen Kurven reduzieren ([Charlton und de Pont, 2007](#)). Die Instruktion, möglichst präzise eine Geschwindigkeit von 100 km/h einzuhalten, sollte eine solche Geschwindigkeitsreduktion vermeiden und die Variabilität im Fahrverhalten der Versuchspersonen reduzieren.

Mit diesen Annahmen zu den Informationsquellen für die drei Aufgaben werden folgende Hypothesen zu den [prozentualen Blickverweilzeiten](#) (PDTs) aufgestellt:

- H1:** Die Erhöhung der Ereignisrate für die Lateralkontrolle erhöht die PDT zur Straße.
- H2:** Die Erhöhung der Ereignisrate für die Nebenaufgabe erhöht die PDT zur Mittelkonsole.
- H3:** Die Erhöhung der Priorität für eine der drei Aufgaben erhöht die PDT zur Informationsquelle der jeweiligen Aufgabe.
- H4:** Da die visuelle Aufmerksamkeit eine begrenzte Ressource ist, führt eine erhöhte PDT für eine Informationsquelle zu einer Reduktion der PDTs der übrigen Informationsquellen.

Das AIE-Modell simuliert eine erhöhte Aufmerksamkeitsverteilung zu einer Aufgabe durch eine erhöhte Auswahlwahrscheinlichkeit des Aufgabenziels. Dies sollte sich daher in einer Veränderung der Blickfrequenzen widerspiegeln. Dabei kann eine erhöhte Aufmerksamkeit auf eine Aufgabe theoretisch sowohl zu einer Erhöhung der Blickfrequenz als auch zu einer Erniedrigung führen. Bei einer sehr hohen Auswahlwahrscheinlichkeit kann eine Aufgabe mehrmals hintereinander ausgewählt werden. Dies führt zu längeren Blicken auf die Informationsquelle der Aufgabe und insgesamt zu einer Reduktion der Blickfrequenz, da weniger Blicktransitionen zu anderen Informationsquellen auftreten.

Es wird daher ein in der Richtung unbestimmter Effekt auf die Blickfrequenz erwartet. Tendenziell sollte jedoch eine Informationsquelle mit niedriger PDT bei Erhöhung der PDT eine Erhöhung der Blickfrequenz aufweisen, während eine Informationsquelle mit sehr hoher PDT eine Verringerung der Frequenz zeigen sollte. In Hypothese H4 ist bereits ausgedrückt, dass eine Änderung der Aufmerksamkeitsverteilung immer alle Informationsquellen betrifft. Daher wird für die Blickfrequenzen auch hier erwartet, dass sich Effekte nicht nur bei den Informationsquellen zeigen, für die die Ereignisraten oder Prioritäten manipuliert wurden, sondern indirekt auch für alle übrigen.

Es werden somit weitere Hypothesen bezüglich der Blickfrequenzen aufgestellt:

H5: Die Erhöhung der Ereignisrate für die Lateralkontrolle verändert sowohl die Blickfrequenz zur Straße als auch zu allen übrigen Informationsquellen.

H6: Die Erhöhung der Ereignisrate für die Nebenaufgabe verändert sowohl die Blickfrequenz zur Mittelkonsole als auch zu allen übrigen Informationsquellen.

H7: Die Erhöhung der Priorität für eine der drei Aufgaben verändert die Blickfrequenz zu der jeweiligen Informationsquelle.

Zur Überprüfung der obigen Hypothesen sind mehrere Hypothesentests erforderlich. Um eine **Inflation des Fehlers 1. Art** zu vermeiden, wird eine sequentielle Bonferroni-Korrektur nach [Holm \(1979\)](#) vorgenommen mit einem globalen α -Wert von 0.05. Dieses Vorgehen ist für das vorliegende Experiment als sehr konservativ einzustufen, da die Hypothesen nicht vollständig unabhängig voneinander sind. Hierauf wird bei der Beschreibung der Ergebnisse in Abschnitt [5.5.1](#) näher eingegangen.

Im folgenden Abschnitt wird die Variation der Ereignisraten und Aufgabenprioritäten sowie der gesamte Versuchsaufbau im Detail beschrieben.

5.2 Versuchsaufbau

5.2.1 Versuchspersonen

Es wurden insgesamt 21 Freiwillige im Alter von 22-54 Jahren ($\bar{M} \approx 32.67$ Jahre) als Teilnehmer zu der Studie eingeladen. Diese Gruppe bestand aus 12 Männern und 9 Frauen. Alle besaßen seit mindestens vier Jahren einen Führerschein ($\bar{M} \approx 14.64$ Jahre) und gaben eine geschätzte, jährliche Kilometerzahl zwischen 0 und 35 000 km ($\bar{M} \approx 12 049$ km) an. Die Teilnehmer sollten sich dabei an den gefahrenen Kilometern im letzten Jahr orientieren. Da nicht alle Teilnehmer ein eigenes Fahrzeug besaßen, lag die jährliche Kilometerzahl bei den Versuchspersonen 17 und 19 lediglich bei 0 bzw. 30 km.

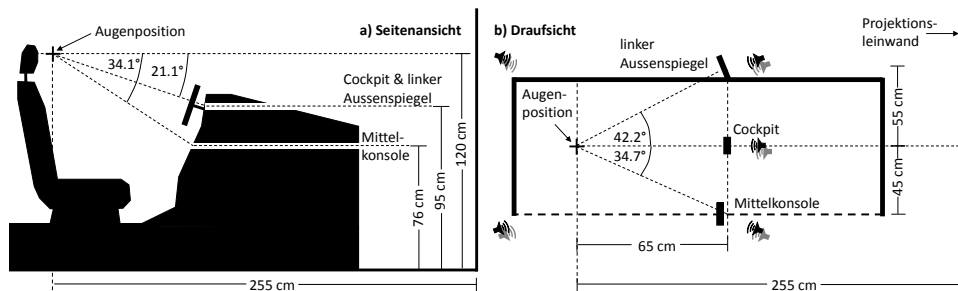



Abbildung 5.2 – Oben: Fahr Simulator in Aktion. Unten: Schematische Ansicht.

Bei den Versuchspersonen 7, 8, 14 und 20 musste der Versuch aufgrund von Simulatorübelkeit abgebrochen werden. Eine detaillierte Beschreibung der Versuchsteilnehmer findet sich in Anhang B.1.


5.2.2 Material

5.2.2.1 Fahr Simulator

Für die Studie wurde der Fahr Simulator des Instituts OFFIS¹ genutzt. Er ist aufgebaut aus einem Fahrersitz, Lenkrad, Pedale, Geschwindigkeitsanzeige, linker Seitenspiegel und der Mittelkonsole (s. Abbildung 5.2). In der Mittelkonsole ist ein Display eingelassen, auf dem eine Nebenaufgabe angezeigt wird (s. Abschnitt 5.2.4). Der Aufbau ist umgeben von drei Leinwänden, auf die für den Fahrer eine 170°-Sicht der Simulationsumgebung projiziert wird. Als Fahr Simulationssoftware kam das SILAB-System der Würzburger Institut für Verkehrswissenschaften GmbH² in der Version 3.0 zum Einsatz.


¹www.offis.de

²www.wivw.de



(a) Brillaufsatz des Eyetrackers

(b) Optische Markierer im Fahr Simulator

Abbildung 5.3 – Das Eye-Tracking System Dikablis**Abbildung 5.4** – Definition der Informationsquellen im Kamerabild der Blickfeldkamera. (A) Straße. (B) Geschwindigkeitsanzeige. (C) Nebenaufgabe. (D) linker Seitenspiegel.

5.2.2.2 Eyetracker

Zur Aufzeichnung der Blickbewegungen wurde das Dikablis Eye-Tracking-System der Ergoneers GmbH³ verwendet. Es besteht aus zwei an einem Brillengestell befestigten Kameras zur Aufzeichnung eines Auges und des Blickfeldes (s. Abbildung 5.3(a)). Um den Zusammenhang zwischen Augenposition im Augenkamerabild und Blickposition im Bild der Blickfeldkamera herzustellen, wird vor jedem Versuch eine Kalibrierung durchgeführt.

Zur automatischen Identifikation der betrachteten Informationsquellen in der Simulationsumgebung und dem Cockpit wurden vier optische Markierer im Cockpit angebracht (s. Abbildung 5.3(b)). Deren Positionen wurden in einem Nachbearbeitungsschritt im Video der Blickfeldkamera identifiziert. Relativ zu den Positionen der Markierer wurden vier Informationsquellen definiert. Hierzu wurde die Analysesoftware D-Lab verwendet. Sie ermöglicht die Auswertung von Blickdaten nach

³www.ergoneers.com

ISO/TS 15007-2 (ISO, 2001). In Abbildung 5.4 ist die Sicht der Blickfeldkamera mit den erkannten Markierern und den Informationsquellen zu sehen. Diese sind das Instrumentenfeld hinter dem Lenkrad mit der Geschwindigkeits- und Drehzahlanzeige, die Sicht nach vorne auf die Straße, das Display der Nebenaufgabe und der linke Seitenspiegel. Die Informationsquellen wurden etwas größer definiert als sie sind, um bei der Blickdatenanalyse robust gegenüber leichten Veränderungen der Brillenposition zu sein.

Da in den ausgewerteten Daten die Anzahl der Blicke zum Seitenspiegel deutlich unter einem Prozent lag, wurde dieser in den Analysen nicht weiter berücksichtigt. Die äußerst geringe Blickverteilung zum Spiegel war zu erwarten, da es keinen umgebenden Verkehr gab, auf den die Versuchspersonen achten mussten.

5.2.3 Streckenverlauf

Um die Ereignisraten der Spurhalteaufgabe zu variieren, wurden drei verschiedene Streckenprofile mit unterschiedlichen Kurvenradien erstellt. Jede Strecke hat eine Länge von acht Kilometern. Bei einer Durchschnittsgeschwindigkeit von 100 km/h entspricht das einer Fahrzeit von ungefähr fünf Minuten.

Das Streckenprofil mit großen Kurvenradien ($1000\text{ m} \leq r \leq 2000\text{ m}$) wird im Folgenden als leichte Streckenbedingung bezeichnet, das Profil mit mittleren Radien ($375\text{ m} \leq r \leq 750\text{ m}$) als mittlere Streckenbedingung und das Profil mit kleinen Radien ($125\text{ m} \leq r \leq 250\text{ m}$) als schwere Streckenbedingung. In Abbildung 5.5 ist die mittlere Streckenbedingung zu sehen. Als Übergang zwischen zwei Kreissegmenten wurde gemäß den Richtlinien für die Anlage von Straßen (Forschungsgesellschaft für Straßen- und Verkehrswesen, 1996a) jeweils eine geeignete Klothoide verwendet. Die angegebenen Längen der Kreissegmente sind inklusive der Klothoiden zu interpretieren.

Das Profil wird zweimal hintereinander gefahren, um insgesamt acht Kilometer Strecke zu erhalten. Die schwere Streckenbedingung wurde aus der mittleren Streckenbedingung durch Verkleinern der Kurvenradien und Verkürzen der Kreissegmente abgeleitet. Die leichte Streckenbedingung wurde analog durch Vergrößern der Radien und Kreissegmente erzeugt.




Abbildung 5.5 – Streckenverlauf bei mittlerer Spurkrümmung. L bezeichnet die Segmentlänge und R den Radius.

5.2.4 Nebenaufgabe

Zu Beginn dieser Arbeit wurde die Entwicklung des AIE-Modell u. a. damit motiviert, das Blickverhalten von Fahrern in Interaktion mit technischen Systemen im Fahrzeug zu beschreiben. Stellvertretend für ein konkretes System (z. B. Handy oder Navigationssystem) wurde den Versuchspersonen eine Nebenaufgabe als **Surrogatsystem** präsentiert. Verwendet wurde der **Number Read Back Task (NRBT)** (Horrey et al., 2006). Bei dieser Nebenaufgabe wurden auf einem Display in der Mittelkonsole des Fahrsimulators (s. Abbildung 5.4, Informationsquelle C) in variierenden Zeitabständen sechsstellige Ziffernblöcke präsentiert. Aufgabe der Versuchspersonen war es, möglichst schnell auf eine neue Zahl zu reagieren, indem sie einen Schalter am Lenkrad betätigen.

Nach Betätigung des Schalters blieben die Ziffern für 1,5 Sekunden angezeigt, in denen die Versuchspersonen die Ziffern laut vorlesen sollten. Fehler beim Vorlesen der Ziffern wurden während des Versuchs protokolliert. Der Zeitpunkt, an dem die Ziffernblöcke angezeigt wurden, und die Reaktionszeiten der Versuchspersonen wurden synchron mit den Simulatordaten aufgezeichnet. Zwischen zwei Ziffernblöcken wurden sechs 'X' präsentiert. Die Versuchspersonen gaben an, den Wechsel von Ziffern und X-Zeichen nicht im **peripheren Blickfeld** wahrzunehmen. Sie mussten daher aktiv den Blick auf das NRBT-Display richten, um das Erscheinen neuer Ziffernblöcke zu erkennen.

Um die **Ereignisrate** der Nebenaufgabe zu variieren, wurden zwei verschiedene Versuchsbedingungen für die Nebenaufgabe erzeugt. In der leichten NRBT-Bedingung wurden neue Ziffernblöcke nach sechs bis zehn Sekunden angezeigt, während diese in der schweren NRBT-Bedingung im Abstand von zwei bis sechs Sekunden angezeigt wurden. Die Abstände wurden zufällig über eine Gleichverteilung im jeweiligen Intervall erzeugt.

5.2.5 Instruktionen

Vor Beginn des Versuchs erhielten die Fahrer lediglich drei einfache Instruktionen:

Lateralkontrolle: Versuchen Sie das Fahrzeug immer möglichst mittig in der Fahrspur zu halten.

Longitudinalkontrolle: Versuchen Sie immer möglichst genau eine Geschwindigkeit von 100 km/h einzuhalten.

Nebenaufgabe: Versuchen Sie immer möglichst schnell korrekt auf die Nebenaufgaben zu reagieren.

Zudem wurden sie aufgefordert, das Fahrzeug trotz der Nebenaufgabe stets sicher zu führen. Das bedeutet in diesem Szenario insbesondere, die Spur nicht zu verlassen. Während des Simulatortrainings wurden die Versuchspersonen mehrfach auf die Instruktionen hingewiesen. Dabei wurde betont, dass alle drei Aufgaben wichtig sind. Ziel dieser Instruktionen war es, ein klares Bild der Aufgabenstruktur von drei parallel zu bearbeitenden Aufgaben bei den Fahrern zu erzeugen. Das ist wichtig für die spätere Evaluierung des Fahrermodells, da die Aufgabenbeschreibung des Fahrermodells eben von einer solchen Struktur ausgeht. Wie bereits in Abschnitt 3.1 angesprochen, ist die Validierung eines Aufgabenmodells oftmals sehr schwierig. Durch die Instruktionen sollte die Variabilität der mentalen Aufgabenrepräsentationen bei den Versuchspersonen reduziert werden.

In den Vorversuchen wurden den Testfahrern diese Instruktionen nicht gegeben. Dies führte dazu, dass sich einer der Testfahrer stark auf die Nebenaufgabe fokussierte, während dies beim anderen Testfahrer nicht der Fall war. Bei den Versuchspersonen ließ sich eine übermäßig starke Fokussierung auf eine der drei Aufgaben nach mehrmaligen Wiederholen der Instruktionen während der Trainingsphase nicht mehr beobachten.

Während der letzten 15 Minuten des Experiments wurden die Auswirkungen der [Aufgabenpriorisierung](#) auf das Blickverhalten untersucht. Um die Aufgabenprioritäten zu manipulieren, wurden die Versuchspersonen in dieser Zeit instruiert, gezielt immer eine der drei Aufgaben besonders zu priorisieren (s. Abschnitt 5.2.6).

5.2.6 Versuchsdesign

Zu Beginn eines jeden Experiments wurden die Versuchspersonen über den Ablauf des Szenarios und die Aufgaben, die sie durchführen sollen, informiert. Anschließend wurde eine Einverständniserklärung zur Teilnahme am Versuch und der Verwendung der aufgezeichneten Daten ausgefüllt. Zudem wurden einige Daten zur Person aufgenommen, wie z.B. Alter und Fahrerfahrung. Die hierfür verwendeten Formulare finden sich in Anhang B.3.

Nachdem die Versuchspersonen im Simulator Platz genommen und den Sitz passend eingestellt hatten, wurde die Eyetrackerkalibrierung durchgeführt. Hierzu wurden sechs Kalibrierungspunkte auf der Simulatorprojektionsfläche verwendet, sowie drei weitere für die anderen Informationsquellen (Tachometer, NRBT-Display, linker Außenspiegel). Nach erfolgreicher Kalibrierung wurden die Versuchspersonen mit der Nebenaufgabe vertraut gemacht. Anschließend absolvierten sie ein etwa zehn minütiges Trainingsszenario. Dieses bestand aus einer kurvigen Strecke mit Kurvenradien aus allen drei Versuchsbedingungen.

Die Fahrzeit im eigentlichen Versuch beträgt 45 Minuten. Der Versuch wurde dabei in zwei Teile unterteilt. In Tabelle 5.1 sind die Ausprägungen der drei unabhängigen Variablen Streckenschwierigkeit, NRBT-Frequenz und [Aufgabenpriorität](#) für alle Versuchsbedingungen in beiden Versuchsteile aufgelistet. Im ersten Teil wur-

	Strecken- schwierigkeit	NRBT- Frequenz	Aufgabenpriorität	
1. Versuchsteil	leicht	leicht	keine	
	mittel	leicht	keine	
	schwer	leicht	keine	
	leicht	schwer	keine	
	mittel	schwer	keine	
	schwer	schwer	keine	
2. Versuchsteil	mittel	leicht	Lateralkontrolle	} Gruppe: mittlere Streckenbedingung
	mittel	leicht	Longitudinalkontrolle	
	mittel	leicht	NRBT	
	schwer	leicht	Lateralkontrolle	} Gruppe: schwere Streckenbedingung
	schwer	leicht	Longitudinalkontrolle	
	schwer	leicht	NRBT	

Tabelle 5.1 – Versuchsbedingungen in beiden Versuchsteilen anhand der drei unabhängigen Variablen: Streckenschwierigkeit, NRBT-Frequenz, Aufgabenpriorität.

den die Auswirkungen der Ereignisraten auf das Blickverhalten untersucht. Daher stellten die NRBT-Aufgabenrate und die Streckenbedingung die zwei unabhängigen Variablen dar mit den Ausprägungen leicht, mittel, schwer für die Streckenbedingung sowie leicht bzw. schwer für die NRBT-Bedingung. Es wurde ein balancierter 3×2 Versuchsplan mit intraindividuellen Messwiederholungen für diese beiden Faktoren entworfen. Jede Versuchsperson fuhr jede Bedingung fünf Minuten am Stück. Die Reihenfolge der Faktorausprägungen wurde randomisiert zugeteilt.

Im zweiten Teil des Versuchs wurde die Auswirkung von Aufgabenprioritäten untersucht. Jede Versuchsperson fuhr 3×5 Minuten eine Strecke mit konstanter Streckenbedingung und konstanter NRBT-Bedingung. Vor jedem der drei Streckenabschnitte wurden die Versuchspersonen instruiert, dass sie die Priorität auf eine der drei Aufgaben (Spurhalten, Geschwindigkeithalten oder Nebenaufgabe) legen sollen. Für die Nebenaufgabe wurde die leichte NRBT-Bedingung gewählt. Bezüglich der Streckenschwierigkeit wurden die Versuchspersonen in zwei Gruppen unterteilt. Eine Gruppe fuhr die schwierige Strecke mit kleinen Kurvenradien und die andere Gruppe fuhr die Strecke mit mittleren Kurvenradien. Obwohl die Daten einiger Versuchspersonen aussortiert werden mussten (s. Abschnitt 5.4.2), ergaben sich für die Blickdatenauswertung gleich große Datensätze von jeweils sieben Versuchspersonen pro Streckenbedingung. Dies resultiert in einem balancierten 2×3 Versuchsplan mit einem Gruppierungsfaktor (Streckenbedingung) und einem Messwiederholungsfaktor (Aufgabenpriorität). Die Reihenfolge der Aufgabenprioritäten wurde randomisiert zugeteilt. Die Zuteilung ist in Anhang B.2 aufgelistet.

5.3 Vorhersagen des SEEV-Modells

Das SEEV-Modell benötigt zur Anwendung kein detailliertes Fahrermodell. Daher kann es hier genutzt werden, um Vorhersagen zu den prozentualen Blickverweilzeiten der Versuchsfahrer zu machen. In Abschnitt 5.5.3 werden die Vorhersagen mit den Experimentdaten verglichen. Ein Vergleich zwischen den vom SEEV-Modell erzeugten Blickverweilzeiten und denen, die vom AIE-Modell erzeugt wurden, wird in Abschnitt 5.8 vorgenommen.

Bei einem vergleichbaren Experiment verwendeten Horrey et al. (2006, 2005) das SEEV-Modell, um die Percentage Dwell Time (PDT) der Versuchsfahrer vorherzusagen. Als unabhängige Variablen wurden ebenfalls die Ereignisraten der Fahraufgabe und einer Nebenaufgabe variiert, sowie eine unterschiedliche Priorisierung der beiden Aufgaben vorgenommen.

Für die Anwendung des SEEV-Modells wird in der vorliegenden Arbeit das gleiche Vorgehen gewählt, wie es auch von Horrey et al. genutzt wurde. Dies soll es einerseits ermöglichen, die Ergebnisse von Horrey et al. in einem sehr ähnlichen Szenario zu überprüfen, und andererseits eine Vergleichbarkeit zwischen den Vorhersagen des SEEV-Modells und des AIE-Modell herzustellen. Das hier durchgeführte Experiment ist ähnlich zu dem von Horrey et al., jedoch nicht identisch.

Horrey et al. (2005) werteten die Daten von 8 Versuchspersonen mit einem Durchschnittsalter von 22.1 Jahren aus, die seit durchschnittlich 5.9 Jahren einen Führerschein besaßen. Die in der vorliegenden Arbeit verwendete Versuchsgruppe (Durchschnittsalter: $\bar{M} = 32.7$ Jahre, Führerschein seit: $\bar{M} = 14.6$ Jahren) ist daher als erfahrener einzuschätzen. Horrey et al. verwendeten einen sehr ähnlich aufgebauten Simulator, der allerdings anstelle der in Abbildung 5.2 dargestellten offenen Fahrerkabine aus einem vollständigen Fahrzeug bestand.

Die Versuchspersonen in Horreys Studie hatten ebenfalls die drei in Abschnitt 5.2

beschriebenen Aufgaben zu bearbeiten. Die Nebenaufgabe (Number Read Back Task) ist identisch mit der in dieser Arbeit verwendeten. Als Zielgeschwindigkeit für die Longitudinalkontrolle wählten Horrey et al. die in den Vereinigten Staaten gängige Geschwindigkeitsbegrenzung für Landstraßen von 55 mph (≈ 90 km/h).

Einer der größten Unterschiede besteht bei der Erzeugung der **Ereignisse** für die Lateralkontrolle. Während Horrey et al. eine gerade Strecke verwendeten, bei der die Ereignisse durch Windböen hervorgerufen wurden, wurden in der vorliegenden Studie die Ereignisse durch unterschiedlich starke Straßenkrümmungen erzeugt. Zudem unterschieden sie bei der **Aufgabenpriorität** Aufgabenpriorisierung nur zwischen der Nebenaufgabe und der Fahraufgabe, wobei letztere sowohl die Lateral- als auch Longitudinalkontrolle beinhaltet.

Horrey et al. verwendeten die **Expected-Value-Formulierung** des SEEV-Modells (s. Abschnitt 2.1.4.4) zur Vorhersage der **PDTs**. Diese berücksichtigt ebenso wie das AIE-Modell nur die **Top-Down-Einflussfaktoren** bei der Vorhersage der Aufmerksamkeitsverteilung. Die Expected-Value-Variante bestimmt das Aufmerksamkeitsgewicht einer Informationsquelle A basierend auf der **Bandbreite** der Informationsquellen, dem Wert (V) der Information und einem Relevanzfaktor (R) (vgl. Gleichung 2.6, S. 28).

Soll die Aufmerksamkeitsverteilung bei einer Menge \aleph von Informationsquellen und einer Menge G von Aufgaben untersucht werden, dann bestimmt die Expected-Value-Formulierung des SEEV-Modells die zu erwartende **Percentage Dwell Time (PDT)** einer Informationsquelle A :

$$PDT(A) = \frac{BW_A \cdot \sum_{g \in G} (R_{A,g} \cdot V_g)}{\sum_{B \in \aleph} (BW_B \cdot \sum_{g \in G} (R_{B,g} \cdot V_g))} \quad (5.1)$$

Um mit dem Expected-Value-Modell die zu erwartenden **PDT**-Werte zu berechnen, müssen die BW -, R -, und V -Parameter bestimmt werden. Für die Bestimmung der BW - und V -Parameter wurde der **Lowest-Ordinal-Algorithmus** angewendet, so wie er auch von Horrey et al. (2006) genutzt wurde. Die aus den Versuchsbedingungen resultierenden Parameter sind in Tabelle 5.2 aufgelistet.

		Relevanz (R)			Ereignisrate (B)					
		Lateral- kontrolle	Longit.- kontrolle	NRBT	Streckenbedingung			NRBT- Bedingung		
Aufgabe	leicht				mittel	schwer	leicht	schwer	alle Bedingun- gen	
AOI	Straße	1	0	0	1	2	3	-	-	-
	Tacho	0	1	0	-	-	-	-	-	1
	NRBT	0	0	1	-	-	-	1	2	-
		Informationswert (V)								
Priorität	keine	2	1	1						
	Lateral	3	1	1						
	Longit.	2	2	1						
	NRBT	2	1	2						

Tabelle 5.2 – Die SEEV-Koeffizienten für alle Versuchsbedingungen nach dem Lowest-Ordinal-Algorithmus.

	Strecke	Versuchsbedingung		Prozentuale Blickverweilzeit		
		NRBT	Priorität	Straße	Tacho	NRBT
1. Versuchsteil	leicht	leicht	keine	0.500	0.250	0.250
	leicht	schwer	keine	0.400	0.200	0.400
	mittel	leicht	keine	0.667	0.167	0.167
	mittel	schwer	keine	0.571	0.143	0.286
	schwer	leicht	keine	0.750	0.125	0.125
	schwer	schwer	keine	0.667	0.111	0.222
2. Versuchsteil	mittel	leicht	Longit. Kontrolle	0.571	0.286	0.143
	schwer	leicht	Longit. Kontrolle	0.667	0.222	0.111
	mittel	leicht	Lateralkontrolle	0.750	0.125	0.125
	schwer	leicht	Lateralkontrolle	0.818	0.091	0.091
	mittel	leicht	NRBT	0.571	0.143	0.286
	schwer	leicht	NRBT	0.667	0.111	0.222

Tabelle 5.3 – Durch das SEEV-Modell vorhergesagte prozentuale Blickverweilzeiten bei Verwendung der Expected-Value Formulierung.

Bei der Bestimmung der Relevanzkoeffizienten werden drei Informationsquellen berücksichtigt: die vorausliegende Straße, die Geschwindigkeitsanzeige und die NRBT-Anzeige. Wie bereits in Abschnitt 5.1 beschrieben, wird hier davon ausgegangen, dass für jede der drei Aufgaben nur eine der Informationsquellen relevant ist.

Da es weder eine Informationsquelle gibt, die für zwei Aufgaben von Relevanz ist, noch eine Aufgabe zwei Informationsquellen benötigt, ergibt sich für die Relevanzkoeffizienten eine Einheitsmatrix. Die Koeffizienten für die Ereignisraten und Informationswerte sind entsprechend ihrer Ausprägung bei eins beginnend geordnet. Bei den Wertfaktoren (V) wird davon ausgegangen, dass der Wert einer Aufgabe steigt, wenn die Versuchspersonen instruiert wurden, diese Aufgabe zu priorisieren. In den Versuchsbedingungen des ersten Versuchsteils, in denen keine Priorisierungsinstruktionen gegeben wurden, wird davon ausgegangen, dass die Lateralkontrolle dennoch einen etwas höheren Wert hat, da die Versuchspersonen aufgefordert wurden, das Fahrzeug in allen Situationen trotz Nebenaufgabe sicher zu führen. Zudem sollte für einen Fahrer die sichere Kontrolle des Fahrzeugs innerhalb der Spur stets einen höheren Wert haben, als die Geschwindigkeitskontrolle oder eine Nebenaufgabe. Die V -Werte für die Lateralkontrolle beginnen daher bei 2 und nicht wie bei den anderen Aufgaben bei 1. Diese Annahme trafen auch Horrey et al. (2005) bei der Auswertung ihrer Studie. Sie wird hier übernommen.

Die prozentualen Blickverweilzeiten, die das Expected-Value-Modell mit diesen Werten vorhersagt, sind in Tabelle 5.3 aufgelistet. In Abschnitt 5.5.3 werden diese Werte mit den tatsächlich gemessenen PDTs verglichen.

5.4 Datenaufbereitung

5.4.1 Datenaufzeichnung

Während der Versuchsfahrten wurden zahlreiche Daten aus der Fahrsoftware, dem Eyetracking-System und zur Nebenaufgabe aufgezeichnet. Die Daten,

Variable	Einheit	Variable	Einheit
<u>Simulatordaten</u> (12 Hz.)		<u>NRBT-Daten</u> (1/Aufgabe)	
Simulationszeit	ms	NRBT-Nummer	Integer
Longitudinale Position	m	VP-Antwort	0 1
Laterale Position	m		
Lenkradwinkel	rad		
Gierwinkel	rad	<u>Eyetrackerdaten</u> (25 Hz.)	
Time to Lane Crossing (TLC)	s	Aufnahmezeit	ms
Gaspedalposition	[0..1]	Videobild Auge	px × px
Bremspedalposition	[0..1]	Videobild Feld	px × px
Geschwindigkeit	m/s	Position der Pupille	px, px
NRBT-Zustand	[0..3]		
NRBT-Nummer	Integer		
NRBT-Reaktionszeit	ms		

Tabelle 5.4 – Aufgezeichnete Daten

die für die Analysen in dieser Arbeit verwendet wurden, sind in Tabelle 5.4 aufgelistet. Für die Datenauswertung wurden die Datenreihen jeder Versuchsperson synchronisiert und in eine einzelne Datenreihe überführt. Die Rate dieser Datenreihe basiert auf der Aufzeichnungsrate der Simulatordaten (12 Hz). Bei der Synchronisation der Datenreihen wurde nicht interpoliert. Aus den Eyetrackerdaten wurde jeweils der Datensatz mit dem kürzesten zeitlichen Abstand zum jeweiligen Simulatordatensatz ausgewählt.

5.4.2 Ausschluss von Datensätzen

Von einigen Versuchspersonen wurden die Datensätze vollständig von der Analyse ausgeschlossen. Hierzu gehören die Datensätze 7, 8, 14 und 20, da die entsprechenden Versuche aufgrund von Simulatorübelkeit abgebrochen wurden.

Weitere Datensätze wurden lediglich von der Analyse des Blickverhaltens ausgeschlossen. Dazu gehört Datensatz 1, da bei diesem Versuch keine Synchronisationsanker aufgezeichnet wurden, die benötigt werden, um die Eyetrackingdaten mit den Simulatordaten in Beziehung zu setzen. Die Blickdaten der Versuchspersonen 3 und 13 wurden ausgeschlossen, da hier der prozentuale Anteil der Zeit, in der der Blick auf keine Informationsquelle gerichtet ist, sehr hoch ist. Dieser Zeitanteil beinhaltet Sakkaden zwischen den Informationsquellen, Blicke zu nicht aufgezeichneten Informationsquellen und Messfehler. Er liegt bei allen übrigen Versuchspersonen zwischen 2,9 % und 12,1 % ($\bar{M} \approx 6,9\%$); Die Versuchspersonen 3 und 13 weisen jedoch einen Anteil von 24,7 % bzw. 36,4 % auf, was auf viele Messfehler hindeutet.

5.4.3 Aufbereitung der Eyetrackerdaten

Es wurde eine Blickidentifizierung mit der D-Lab Experimentalsoftware durchgeführt. Diese nutzt eine regionsbasierte Blickbestimmung (vgl. [Salvucci, 1999](#)), wie es von der ISO 15007 zur Analyse des Fahrerblickverhaltens vorgegeben ist. Fehlende Messwerte aufgrund von Augenzwinkern wurden durch die D-Lab Software interpoliert.

5.4.4 Datenselektion

Da die Versuchspersonen zu Beginn eines jeden Versuchsblocks das Fahrzeug zuerst auf die Zielgeschwindigkeit beschleunigen müssen, unterscheidet sich ihr Fahr- und Blickverhalten zu Beginn eines Versuchsblocks vom restlichen Verlauf. Das Ende eines Blocks wurde durch ein Stoppschild angezeigt. Hier weicht das Verhalten durch das Abbremsen vom restlichen Verlauf ab. Die Daten der ersten 200 Streckenmeter und der letzten 200 Streckenmeter eines jeden Versuchsblocks wurden daher von der Datenauswertung ausgeschlossen.

5.5 Ergebnisse

Es folgt nun die Beschreibung der Versuchsergebnisse. Später in Abschnitt 5.8 werden diese Daten mit dem Verhalten des Fahrermodells verglichen.

5.5.1 Einfluss der unabhängigen Variablen auf das Blickverhalten

Für die in Abschnitt 5.1 aufgestellten Hypothesen bezüglich des Einflusses der Ereignisraten und Aufgabenprioritäten auf die prozentualen Blickverweilzeiten und die Blickfrequenzen wurden Varianzanalysen durchgeführt. Die Ergebnisse werden im Folgenden beschrieben.

5.5.1.1 Einfluss der Ereignisraten

Die in diesem Abschnitt beschriebenen Analysen beziehen sich ausschließlich auf den ersten Versuchsteil, in dem die Ereignisraten für die Lateralkontrolle und die Nebenaufgabe manipuliert wurden.

5.5.1.1.1 Prozentuale Blickverweilzeit

In Abbildung 5.6 sind die gemessenen prozentualen Blickverweilzeiten zu den drei Informationsquellen in Abhängigkeit von der Ereignisrate aufgetragen. Im linken Diagramm wurde die Ereignisrate für die Lateralkontrolle durch unterschiedliche Streckenbedingungen verändert. Im rechten Diagramm wurde die Ereignisrate für die Nebenaufgabe durch unterschiedlich hohe Frequenzen neuer NRBT-Ziffernblöcke verändert. Wie in Hypothese H1 erwartet, steigt die Blickzuwendung zur Straße mit Erhöhung der Ereignisrate für die Lateralkontrolle ($F_{2,26} = 120.72, p < 0.001$). Das gleiche gilt für die Blickzuwendung zum NRBT-Display (Hypothese H2). Mit Erhöhung der NRBT-Aufgabenfrequenz steigt die PDT zum NRBT-Display ($F_{1,13} = 17.84, p < 0.001$).

Die Verminderung der Blickzuwendung zu den jeweils anderen Informationsquellen zeigt sich größtenteils signifikant (Hypothese H4). Die Kennzahlen der zugehörigen Varianzanalysen sind in Tabelle 5.5 aufgelistet. Hier ist lediglich die Verringerung der Blickzuwendung zur Geschwindigkeitsanzeige bei Erhöhung der NRBT-Aufgabenrate nicht signifikant ($F_{1,13} = 0.81, p = 0.386$). Allerdings wurde auch vom SEEV-Modell der kleinste Effekt eben bei Veränderung der NRBT-Ereignisrate für die PDT zum Tachometer vorhergesagt (s. Abschnitt 5.3).

Um den Grund für den Effekt der Streckenbedingung zu lokalisieren, wurden Mehrfachvergleiche zwischen den aufeinanderfolgenden Stufen der Streckenbedingung durchgeführt. Sowohl zwischen der leichten und mittleren als auch der mittleren

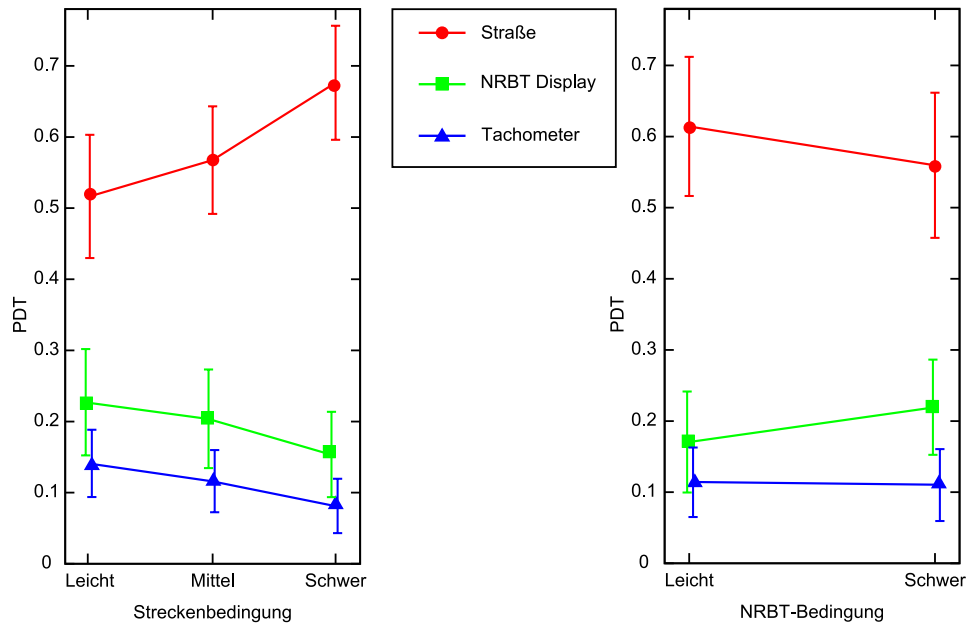


Abbildung 5.6 – Prozentuale Blickverweilzeiten in Abhängigkeit der Streckenbedingung und der NRBT-Aufgabenrate.

Unabhängige Variable	Informationsquelle		
	Straße	NRBT-Display	Tachometer
Streckenbedingung	$F_{2,26}=120.7, p<0.001$	$F_{2,26}=87.48, p<0.001$	$F_{2,26}=32.9, p<0.001$
Leicht ↔ Mittel	$t=5.607, p<0.001$	$t=8.829, p<0.001$	$t=3.589, p=0.001$
Mittel ↔ Schwer	$t=9.747, p<0.001$	$t=4.115, p<0.001$	$t=4.508, p<0.001$
NRBT-Bedingung	$F_{1,13}=29.06, p<0.001$	$F_{1,13}=17.84, p<0.001$	$F_{1,13}=0.81, p=0.386$

Tabelle 5.5 – Kenngrößen der Varianzanalyse für die PDTs im 1. Versuchsteil.

und schweren Bedingung zeigt sich für jede Informationsquelle ein signifikanter Effekt.

5.5.1.1.2 Blickfrequenzen

Der Einfluss der Ereignisraten auf die Blickfrequenzen ist in Abbildung 5.7 dargestellt. Die Streckenschwierigkeit hat einen signifikanten Effekt auf die Blickfrequenzen zu allen drei Informationsquellen (Hypothese H5). Die Kennzahlen der Analysen sind in Tabelle 5.6 aufgelistet.

Mehrfachvergleiche für die Effekte der Streckenschwierigkeit zeigen, dass die Manipulation der Streckenschwierigkeit bei allen drei Informationsquellen lediglich zwischen der mittleren und der schweren Bedingung zu einem signifikanten Effekt führt. Demnach passen die Fahrer ihre Blickfrequenz vor allem in der Situation an, in der eine sehr hohe Ereignisrate durch die Spurhalteaufgabe erzeugt wird.

In Abbildung 5.7 (links) ist zu erkennen, dass bei der schwierigen Streckenbedingung die Blickfrequenzen zu allen Informationsquellen zurück gehen. Bei den PDTs hat sich hier ein anderes Bild dargestellt. Die PDT zur Straße steigt in der schwierigen Streckenbedingung an, während alle anderen PDTs geringer werden. Der Grund




Abbildung 5.7 – Blickfrequenzen in Abhängigkeit der Streckenbedingung und der NRBT-Aufgabenrate.

Unabhängige Variable	Informationsquelle		
	Straße	NRBT-Display	Tachometer
Streckenbedingung	$F_{2,26}=11.49, p<0.001$	$F_{2,26}=12.04, p<0.001$	$F_{2,26}=13.0, p<0.001$
Leicht ↔ Mittel	$t=0.101, p=0.921$	$t=0.164, p=0.871$	$t=1.713, p=0.099$
Mittel ↔ Schwer	$t=4.100, p<0.001$	$t=4.165, p<0.001$	$t=3.321, p=0.003$
NRBT-Bedingung	$F_{1,13}=5.26, p=0.039$	$F_{1,13}=7.06, p=0.020$	$F_{1,13}=4.69, p=0.049$

Tabelle 5.6 – Kenngrößen der Varianzanalyse für die Blickfrequenzen im ersten Versuchsteil.

für die reduzierte Blickfrequenz zur Straße liegt darin, dass die Blickfrequenz zur Straße generell schon sehr hoch ist und sich kaum noch steigern lässt. Die erhöhte Schwierigkeit der Spurhalteaufgabe führt daher nicht dazu, dass die Blickfrequenz zur Straße steigt, sondern der Blick länger auf die Straße gerichtet bleibt. Diese Erhöhung der Blickdauer zur Straße (leicht: $\bar{M} = 0.98$ s, mittel: $\bar{M} = 1.08$ s, schwer: $\bar{M} = 1.55$ s) reduziert nicht nur die Blickfrequenz zur Straße, sondern auch zu den anderen Informationsquellen.

Ein anderes Bild zeigt sich bei der NRBT-Aufgabenrate (Abbildung 5.7, rechts). Eine erhöhte Aufgabenrate führt nicht nur zu einer steigenden Blickfrequenz zum NRBT-Display sondern auch zur Straße, während sich die Blickfrequenz zur Geschwindigkeitsanzeige verringert. Der Fahrer hat die meiste Zeit den Blick auf die Straße gerichtet. Um den Anforderungen einer erhöhten Ereignisrate der Nebenaufgabe gerecht zu werden, richtet er daher den Blick häufiger von der Straße auf das NRBT-Display und wieder zurück. Dadurch wird die Blickfrequenz zu beiden Informationsquellen erhöht. Dies führt insgesamt auch zu deutlich kürzeren Blicken zur Straße in der schweren NRBT-Bedingung (leicht: $\bar{M} = 1.3$ s, schwer: $\bar{M} = 1.1$ s). Die Kennzahlen für die Effekte der NRBT-Aufgabenrate auf die Blickfrequenz zu

jeder der drei Informationsquellen sind ebenfalls in Tabelle 5.6 aufgelistet. Jede Analyse für sich liegt im 5 %-Signifikanzbereich. Aufgrund der Bonferroni-Holm-Korrektur (s. Abschnitt 5.1) sind jedoch alle Effekte knapp als nicht signifikant einzustufen. Es sei darauf hingewiesen, dass die Korrektur für die durchgeführten Analysen etwas konservativ ist, da die Hypothesen nicht unabhängig voneinander sind. Dies lässt sich gut anhand des bereits beschriebenen Effekts im linken Diagramm von Abbildung 5.7 illustrieren. Die erhöhte Blickfrequenz zur Straße ist eine direkte Konsequenz aus der erhöhten Blickfrequenz zum NRBT-Display und daher nur indirekt auf die veränderte Ereignisrate für den NRBT zurückzuführen. Trotz dieser Zusammenhänge, wäre eine Wiederholung des Versuchs wünschenswert, um Klarheit über den Einfluss der NRBT-Aufgabenrate auf die Blickfrequenzen zu erlangen.

5.5.1.2 Einfluss der Aufgabenpriorisierung

Die folgenden Analysen der PDTs und Blickfrequenzen beziehen sich ausschließlich auf den zweiten Versuchsteil, in dem die **Aufgabenprioritäten** manipuliert wurden. Die Ergebnisse sind grafisch in Abbildung 5.8 dargestellt.

Bei der Untersuchung des Blickverhaltens zeigten sich bei allen drei Informationsquellen signifikante Haupteffekte sowohl bei den prozentualen Blickverweilzeiten als auch bei den Blickfrequenzen. Die Kennzahlen für die Varianzanalysen sind in Tabelle 5.7 aufgelistet. Mehrfachvergleiche zwischen den einzelnen Aufgabenpriorisierungen zeigten, dass signifikante Effekte bei einer Informationsquelle immer genau dann auftraten, wenn in einer Priorisierungsbedingung die zugehörige Aufgabe priorisiert wurde und in der anderen nicht. Dies gilt sowohl für die PDTs (Hypothese H3) als auch für die Blickfrequenzen (Hypothese H7). Wenn die Aufgabe bei zwei Bedingungen nicht priorisiert wurde, trat zwischen diesen beiden auch kein Effekt auf.

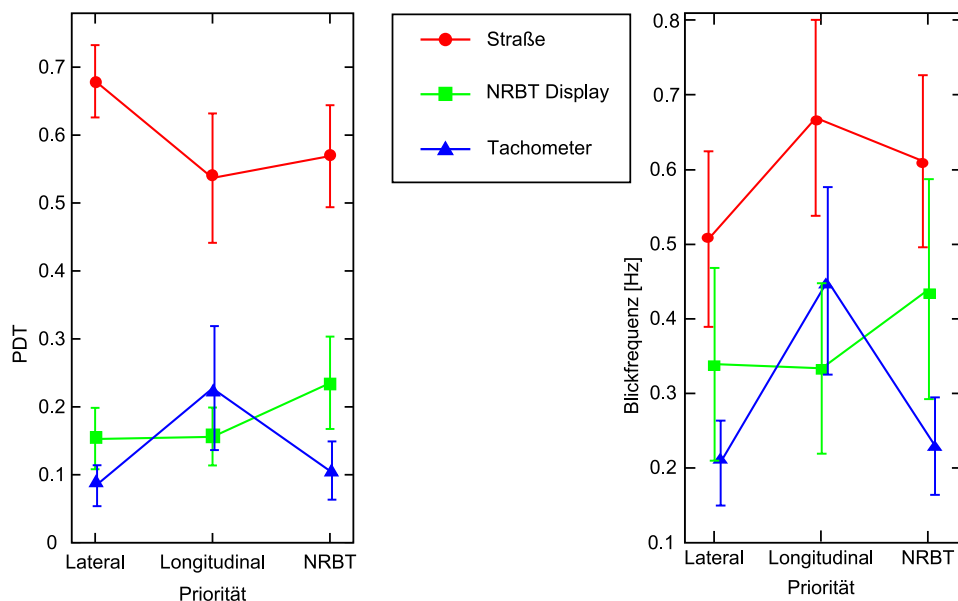


Abbildung 5.8 – PDTs und Blickfrequenzen in Abhängigkeit der Aufgabenpriorisierung.

Unabhängige Variable	Informationsquelle		
	Straße	NRBT-Display	Tachometer
Prozentuale Blickverweilzeit			
Aufgabenpriorität	$F_{2,24}=61.20, p<0.001$	$F_{2,24}=32.60, p<0.001$	$F_{2,24}=48.2, p<0.001$
Lateral ↔ Longit.	$t=5.878, p<0.001$	$t=0.073, p=0.942$	$t=5.072, p<0.001$
Lateral ↔ NRBT	$t=4.952, p<0.001$	$t=4.078, p<0.001$	$t=1.232, p=0.230$
Longit. ↔ NRBT	$t=0.926, p=0.364$	$t=4.005, p<0.001$	$t=3.840, p<0.001$
Strecke	$F_{1,12}=4.855, p=0.048$	$F_{1,12}=2.84, p=0.118$	$F_{1,12}=1.23, p=0.288$
Blickfrequenz			
Aufgabenpriorität	$F_{2,24}=30.47, p<0.001$	$F_{2,24}=27.26, p<0.001$	$F_{2,24}=60.5, p<0.001$
Lateral ↔ Longit.	$t=5.201, p<0.001$	$t=0.028, p=0.978$	$t=6.301, p<0.001$
Lateral ↔ NRBT	$t=3.209, p=0.004$	$t=3.605, p=0.001$	$t=1.256, p=0.221$
Longit. ↔ NRBT	$t=1.992, p=0.058$	$t=3.578, p=0.002$	$t=5.044, p<0.001$
Strecke	$F_{1,12}=0.002, p=0.962$	$F_{1,12}=0.30, p=0.596$	$F_{1,12}=0.24, p=0.631$

Tabelle 5.7 – Kenngrößen der Varianzanalyse für die PDTs und Blickfrequenzen im zweiten Versuchsteil.

Wie bei der Erhöhung der Ereignisraten, führte die Erhöhung der Aufgabenpriorität bei den beiden Aufgaben mit kleiner PDT (NRBT und Longitudinalkontrolle) zu einer Erhöhung der Blickfrequenz, während die Blickfrequenz für die Lateralkontrolle abnahm.

Ein signifikanter Effekt der Streckenschwierigkeit konnte nicht gezeigt werden. Lediglich für die PDT zur Straße deutet sich ein leichter Effekt an. Dieser ist jedoch nicht signifikant. Da sich im ersten Versuchsteil ein deutlicher Effekt der Streckenmanipulation zeigte, liegt hier die Vermutung nahe, dass eine mögliche Ursache für die Unterschiede im ersten und zweiten Versuchsteil im Versuchsdesign begründet liegt. Im zweiten Versuchsteil war die Streckenbedingung nicht als Messwiederholungsfaktor konzipiert. Die Fahrer wurden in zwei Gruppen für die mittlere und schwere Streckenbedingungen aufgeteilt. Dadurch waren weniger Datenpunkte für jede Versuchsbedingung vorhanden und die Teststärke für die Effekte der Streckenmanipulation reduzierte sich.

5.5.2 Einfluss der unabhängigen Variablen auf die Aufgabebearbeitung

Land und Tatler (2009, S.7) sehen die wichtigste Aufgabe der visuellen Wahrnehmung darin, die benötigten Informationen zur Bearbeitung der aktuellen Aufgabe zu beschaffen. Es kann daher angenommen werden, dass Änderungen im Blickverhalten Auswirkungen auf die Qualität der Aufgabebearbeitung haben.

Es wird im Folgenden die Qualität der Fahrzeugführung und die Bearbeitung der Nebenaufgabe betrachtet. Für mehrere Kenngrößen, die die Qualität der Aufgabebearbeitung beschreiben, wurden Signifikanzanalysen durchgeführt. Diese sind explorativer Natur. Das bedeutet, sie wurden nicht aufgrund von a priori Hypothesen durchgeführt. Explorative Analysen dienen typischerweise dazu, unbekannte Zusammenhänge zu entdecken, die schließlich wiederum als Grundlage für a priori Hypothesen in späteren Experimenten dienen können (Jaeger und Halliday, 1998). Bei der Bewertung der Ergebnisse gilt dies zu beachten, da bei einer großen Anzahl an statistischen Tests auf dem gleichen Datensatz für gewöhnlich das Alpha-Level verringert wird, um Fehler 1. Art zu vermeiden. Bei explorativen Analysen soll jedoch die Wahrscheinlichkeit für Fehler 2. Art reduziert werden, um zu vermeiden, dass potentielle Zusammenhänge übersehen werden. Daher wird das Alpha-Level

nicht reduziert.

Mit Blick auf das Fahrermodell dienen diese Analysen hier vor allem dazu, zu untersuchen, wie sich die oben beschriebenen Unterschiede hinsichtlich des Blickverhaltens im Fahrverhalten und der Bearbeitung der Nebenaufgabe widerspiegeln. Bei der Simulation des Fahrermodells wird später geprüft, ob entdeckte Muster und Auffälligkeiten im Verhalten des Fahrermodells wiedergefunden werden können. Für die Analysen, für die sich signifikante Effekte zeigten, werden die Kenngrößen der Varianzanalysen im Text wiedergegeben. Eine vollständige tabellarische Auflistung der Kenngrößen aller Analysen findet sich in Anhang B.5.

5.5.2.1 Einfluss der Ereignisraten

Wie bereits bei der Analyse des Blickverhaltens wird zuerst der erste Versuchsteil betrachtet, bei dem die Ereignisraten für die Lateralkontrolle und die Nebenaufgabe manipuliert wurden.

5.5.2.1.1 Fahrverhalten

In Kapitel 1 wurde die Modellierung der Aufmerksamkeitsverteilung von Autofahren damit motiviert, dass eine unzureichende Verteilung der Aufmerksamkeit auf die Fahraufgabe häufig zu unsicheren Fahrweisen führt und eine Ursache von Unfällen ist. Die oben beschriebenen Effekte auf die Aufmerksamkeitsverteilung der Versuchspersonen lassen daher auch Auswirkungen auf die Qualität der Fahrzeugführung erwarten, die sich in diesem Experiment vor allem aus dem Einhalten der Sollgeschwindigkeit und dem sicheren Führen des Fahrzeugs in der Spur zusammensetzt.

Als Gütemaß für das Führen des Fahrzeugs in der Spur lässt sich die durchschnittliche Abweichung von der Spurmitte berechnen. Bei dem verwendeten Versuchsaufbau führt dies jedoch zu systematischen Fehlern, deren Ursache im Aufbau der Simulatorhardware vermutet wird. Wie in Abbildung 5.2 (S. 118) zu sehen ist, besteht der Fahrsimulator lediglich aus einem halben Fahrzeugaufbau ohne Dach und




Abbildung 5.9 – Güte der Lateralkontrolle in Abhängigkeit von der Streckenbedingung und der NRBT-Aufgabenrate, gemessen an der durchschnittlichen Abweichung von der mittleren Spurposition

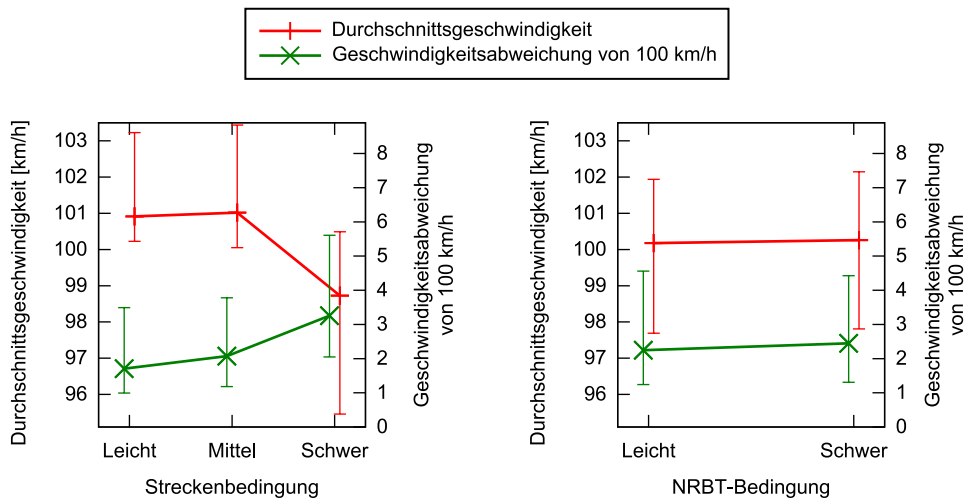


Abbildung 5.10 – Güte der Longitudinalkontrolle in Abhängigkeit von der Streckenbedingung und der NRBT-Aufgabenrate, gemessen an der Durchschnittsgeschwindigkeit und mittleren Abweichung von der Sollgeschwindigkeit von 100 km/h.

A-Säulen. Dies erschwert es, eine genaue laterale Position des simulierten Fahrzeugs in der Spur wahrzunehmen. Eine Analyse der mittleren Abweichungen für jede Versuchsperson ergab, dass alle Versuchspersonen dazu tendieren links der Spurmitte zu fahren. Im Durchschnitt betrug diese Abweichung 38 cm. Dies deutet auf eine leichte Fehlplatzierung der Simulatorhardware hin. Zudem ist die Varianz der durchschnittlichen Abweichung zwischen den Versuchspersonen deutlich höher als die durchschnittliche Varianz innerhalb der Versuchspersonen. Dies ist ein Indiz dafür, dass die Fahrzeugposition von den Versuchspersonen unterschiedlich wahrgenommen wurde. Aus diesen Gründen wurde separat für jede Versuchsperson die durchschnittliche laterale Position des Fahrzeugs in der Spur berechnet. Als Gütemaß für die Lateralkontrolle wurde die aktuelle Abweichung der Fahrzeugposition von der durchschnittlichen lateralen Position verwendet. Die berechneten durchschnittlichen Abweichungen von der mittleren Spurposition sind in Abbildung 5.9 aufgetragen.

Als Gütemaß für die Longitudinalkontrolle wurde die durchschnittliche Abweichung zur Zielgeschwindigkeit von 100 km/h gewählt ($\overline{\Delta v}_{100}$). Im Gegensatz zur Spurposition lässt sich die absolute Geschwindigkeit sehr genau wahrnehmen, da sie direkt vom Tachometer abgelesen werden kann. Die durchschnittlichen Geschwindigkeiten (\bar{v}) in den einzelnen Versuchsbedingungen wurden berechnet, um zu untersuchen, ob die Versuchspersonen die Geschwindigkeit unter schweren Strecken- oder NRBT-Bedingungen reduzieren. In Abbildung 5.10 sind $\overline{\Delta v}_{100}$ und \bar{v} für jede Versuchsbedingung aufgetragen.

Die Veränderung der NRBT-Aufgabenrate lässt weder beim Geschwindigkeits- noch beim Spurhalten einen Effekt erkennen (s. Abbildungen 5.9 und 5.10 (rechts)). Eine Erhöhung der Kurvenkrümmung führt dagegen zu einer stärkeren durchschnittlichen Abweichung von der mittleren Spurposition ($F_{2,32} = 95.8, p < 0.001$) (s. Abbildung 5.9, links). Wie auch bei den Blickfrequenzen und -verweilzeiten ist der Effekt zwischen der mittleren und der schweren Streckenbedingung am größten. Anschließende Mehrfachvergleiche zeigten jedoch einen signifikanten Effekt für jede Stufe der Streckenschwierigkeit.

Bezüglich der Geschwindigkeitskontrolle zeigt sich bei Erhöhung der Kurvenkrümmung sowohl ein signifikanter Effekt bei der Abweichung zur Sollgeschwindigkeit ($F_{2,32} = 13.07, p < 0.001$), als auch bei der durchschnittlichen Geschwindigkeit ($F_{2,32} = 16.81, p < 0.001$) (s. Abbildung 5.10, links). Wie zu erwarten steigt die Abweichung von der Sollgeschwindigkeit mit schwierigeren Streckenbedingungen. Die Durchschnittsgeschwindigkeit ist in der schwierigen Streckenbedingung etwa 2 km/h geringer als in den anderen Bedingungen (s. Abbildung 5.10, links). Anschließende Mehrfachvergleiche zeigten, dass nur der Effekt zwischen der mittleren und der schweren Streckenbedingung signifikant ist, nicht jedoch zwischen der leichten und mittleren.

Die starken Effekte, die sich bei den bisherigen Beobachtungen zwischen der mittleren und der schweren Streckenbedingung zeigten, lassen vermuten, dass die drei Aufgaben in der schweren Streckenbedingung die Versuchspersonen sehr stark belasten und die Reduzierung der Geschwindigkeit ein kompensatorisches Verhalten darstellt. Generell lässt sich in Situationen, in denen Fahrer so schnell fahren können, wie sie wollen, ein Zusammenhang zwischen Kurvenradius und gewählter Geschwindigkeit beobachten (Odhams und Cole, 2004; Reymond et al., 2001). Die Vorgabe von 100 km/h als Geschwindigkeit scheinen einige Versuchspersonen in der schwierigen Streckenbedingung als zu unsicher zu empfinden.

5.5.2.1.2 Bearbeitung der Nebenaufgabe

Ähnlich wie bei der Fahraufgabe lassen sich auch Auswirkungen auf die Qualität der Nebenaufgabe erwarten. Als ein Gütemaß für die Bearbeitung des NRBT kann die Reaktionszeit verwendet werden, gemessen vom Erscheinen einer neuen Aufgabe bis zum Druck des Tasters am Lenkrad. Ein weiteres Maß lässt sich über die Anzahl an Fehlern bei der Bearbeitung bestimmen. Als Fehler wurde gewertet, wenn eine Versuchsperson den Lenkradschalter betätigte, während keine NRBT-Ziffernfolge angezeigt wurde, oder wenn ein Fehler beim Vorlesen der Ziffernfolge auftrat. Beide Maße sind in Abbildung 5.11 eingezeichnet. Die Fehlerhäufigkeit gibt hier die durchschnittliche Anzahl an Fehlern innerhalb der fünfminütigen Versuchsbedingungen an.

Die Erhöhung der Kurvenkrümmung führt zu einem signifikanten Anstieg der Reaktionszeiten ($F_{2,32} = 13.51, p < 0.001$). Anschließende Mehrfachvergleiche zeigten, dass dieser Effekt nur zwischen der mittleren und der schweren Streckenbedingung signifikant ist ($t = 4.337, p < 0.001$). Ähnliche Beobachtungen wurden bereits bei den Blickfrequenzen und dem Fahrverhalten gemacht, bei denen sich auch nur zwischen der mittleren und schweren Streckenbedingung signifikante Effekte zeigten. Eine Ursache für die unterschiedlichen Reaktionszeiten sind sicherlich die unterschiedlichen Blickdauern. Mit steigender Kurvenkrümmung nimmt die Blickdauer zur Straße zu. Es ist leicht ersichtlich, dass sich dadurch die **Blickablenkungsdauer** vom NRBT-Display erhöht und damit auch die Reaktionszeiten für die Nebenaufgabe, da Ereignisse auf dem NRBT-Display nicht so schnell erkannt werden können. Der leichte Rückgang der Reaktionszeiten bei Erhöhung der NRBT-Rate ist dagegen nicht signifikant ($F_{1,16} = 0.71, p = 0.411$).

Bei der Fehlerhäufigkeit zeigt sich ein anderes Ergebnis. In Abbildung 5.11(a) (links) ist gut zu erkennen, dass die durchschnittliche Anzahl an Fehlern zwar mit der Schwierigkeit der Fahraufgabe steigt. Allerdings variierten die Fehlerraten stark, so dass die Ergebnisse hier nicht signifikant sind ($F_{2,32} = 0.99, p = 0.382$). Der leichte Anstieg der Mittelwerte bei steigender Streckenschwierigkeit wird begleitet von einem starken Anstieg der Standardabweichungen. Dies kann ein Indiz dafür sein, dass die Versuchspersonen unterschiedlich stark von der Streckenschwierigkeit

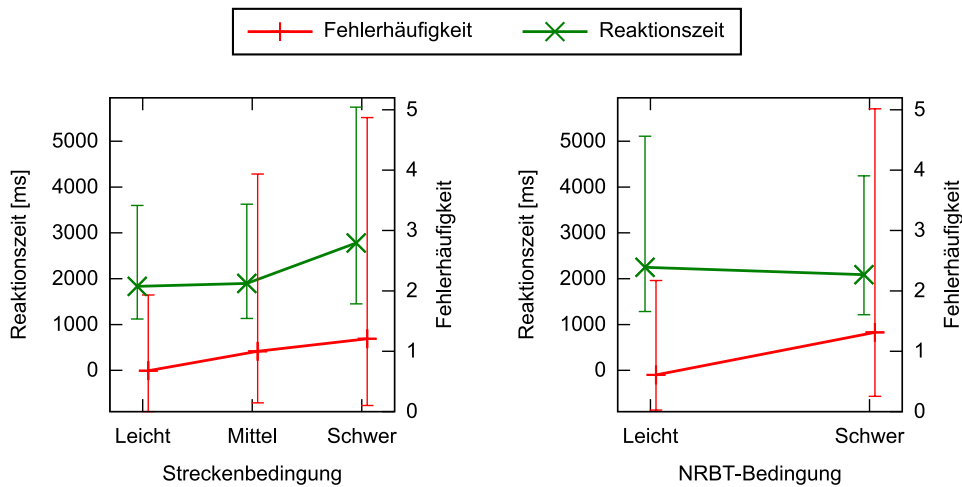


Abbildung 5.11 – Reaktionszeiten und Fehlerhäufigkeiten bei den NRBT-Aufgaben in Abhängigkeit von der Streckenbedingung und der NRBT-Aufgabenrate. Reaktionszeiten wurden gemessen vom Erscheinen einer neuen Ziffernfolge bis zum Betätigen des Schalters.

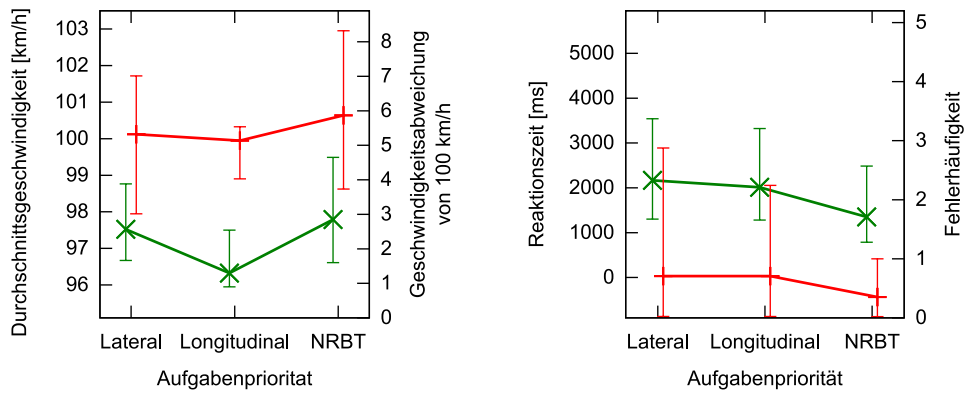
in der Bearbeitung der NRBT beeinträchtigt wurden.

Bei der Manipulation der NRBT-Ereignisrate zeigte sich ein signifikanter Effekt nur bei der Fehlerrate. Das ist jedoch der Tatsache zu schulden, dass in der schwierigen NRBT-Bedingung mehr Aufgaben präsentiert werden und damit auch das Fehlerpotential steigt.

5.5.2.2 Einfluss der Aufgabenpriorisierung

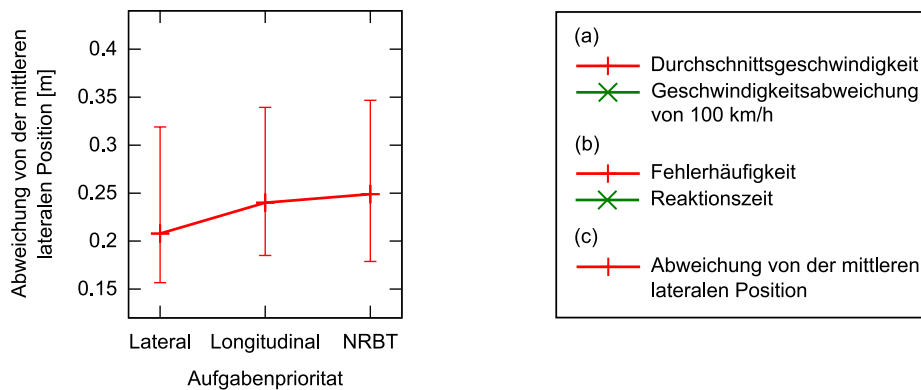
Die unterschiedliche **Priorisierung** hatte einen positiven Einfluss auf die Bearbeitungsqualität der jeweils priorisierten Aufgaben. Die beobachteten Gütemaße für die Bearbeitung der Lateralkontrolle, Longitudinalkontrolle und NRBT sind in Abbildung 5.12 dargestellt. Die geringsten Abweichungen von der mittleren Spurposition wurden bei Priorisierung der Lateralkontrolle erzielt ($F_{2,30} = 9.55, p < 0.001$). Bei Priorisierung der Longitudinalkontrolle wurde dagegen die kleinste Abweichung zur Sollgeschwindigkeit erreicht ($F_{2,30} = 17.09, p < 0.001$). Die kürzesten NRBT-Reaktionszeiten wurden schließlich bei Priorisierung der Nebenaufgabe beobachtet ($F_{2,30} = 58.88, p < 0.001$). Anschließende t-Tests zeigten, dass für eines dieser drei Gütemaße tatsächlich immer nur ein signifikanter Effekt zwischen einer Bedingung, bei der die jeweilige Aufgabe priorisiert wurde, und einer der anderen beiden Bedingungen auftrat. Zwischen den Bedingungen, bei denen die Aufgabe nicht priorisiert wurde, zeigten sich nie signifikante Effekte. Die Kennwerte für alle durchgeführten t-Tests sind in Anhang B.5 aufgelistet.

Kein signifikanter Effekt zeigte sich für die Durchschnittsgeschwindigkeiten (Abbildung 5.12(a)). Diese waren in allen Bedingungen ähnlich gut, jedoch mit 99,95 km/h bei Priorisierung der Longitudinalkontrolle am besten ($F_{2,30} = 1.16, p = 0.328$). Bei der Fehlerhäufigkeit zeigte sich ebenfalls kein signifikanter Effekt ($F_{2,30} = 1.00, p = 0.381$) (Abbildung 5.12(b)), auch wenn hinsichtlich der Durchschnittswerte ein Rückgang der Fehlerrate bei Priorisierung der Nebenaufgabe zu erkennen ist. Wie im ersten Versuchsteil war aber auch im zweiten Teil die Varianz der Fehlerrate



(a) Durchschnittsgeschwindigkeit und Abweichung von der Sollgeschwindigkeit pro Aufgabenpriorität.

(b) NRBT-Reaktionszeit und Fehlerhäufigkeit pro Aufgabenpriorität.



(c) Abweichung von der mittleren lateralen Position pro Aufgabenpriorität.

Abbildung 5.12 – Gütemaße der Lateral- und Longitudinalkontrolle sowie der NRBT-Bearbeitung.

innerhalb der Versuchspersonen sehr hoch, so dass der Effekt nicht signifikant ist.

5.5.3 Vergleich zu den Vorhersagen des SEEV-Modells

Mit dem SEEV-Modell wurden in Abschnitt 5.3 numerische Vorhersagen zur Blickverteilung der Versuchspersonen gemacht. Diese Vorhersagen können nun mit den Experimentergebnissen verglichen werden.

In Tabelle 5.8 sind die im Versuch gemessenen prozentualen Blickverweilzeiten gemittelt über alle Versuchspersonen für jede Versuchsbedingung abgebildet. Die Vorhersagen der Expected-Value-Variante des SEEV-Modells (s. Tabelle 5.3, S. 125) decken sich gut mit den Versuchsergebnissen ($R^2 = 0.958$, $\text{RMSD} = 0.058$). Zur Veranschaulichung sind in Abbildung 5.13 die hier gemessenen Werte gegen die vom SEEV-Modell vorhergesagten Werte aufgetragen. Dieses Resultat stützt die Ergebnisse von Horrey et al. (2005). Sie erzielten mit $R^2 = 0.92$ eine ähnlich ho-

	Strecke	Versuchsbedingung		Prozentuale Blickverweilzeit		
		NRBT	Priorität	Straße	Tacho	NRBT
1. Versuchsteil	leicht	leicht	keine	0.549	0.147	0.201
	leicht	schwer	keine	0.484	0.135	0.253
	mittel	leicht	keine	0.588	0.114	0.175
	mittel	schwer	keine	0.548	0.117	0.232
	schwer	leicht	keine	0.706	0.082	0.134
	schwer	schwer	keine	0.647	0.080	0.173
2. Versuchsteil	mittel	leicht	Longit. Kontrolle	0.488	0.257	0.171
	schwer	leicht	Longit. Kontrolle	0.586	0.197	0.140
	mittel	leicht	Lateralkontrolle	0.636	0.093	0.163
	schwer	leicht	Lateralkontrolle	0.723	0.073	0.142
	mittel	leicht	NRBT	0.533	0.106	0.257
	schwer	leicht	NRBT	0.606	0.105	0.213

Tabelle 5.8 – Mittelwerte der prozentualen Blickverweilzeiten (PDTs) der Versuchspersonen für jede Versuchsbedingung und jede Informationsquelle.




Abbildung 5.13 – Vergleich der gemessenen prozentualen Blickverweilzeiten und der vom SEEV-Modell vorhergesagten Zeiten ($R^2 = 0.958$).

he Korrelation der PDTs. Es zeigt, dass die hier vorgenommene Manipulation der Ereignisrate durch Veränderung der Straßenkrümmung einen ähnlichen Effekt hat, wie die unterschiedlichen Häufigkeiten von Windböen, mit denen Horrey et al. die Ereignisrate manipulierten.

Für das AIE-Modell wird erwartet, dass die Vorhersagen eine ähnliche Güte aufweisen. Dies wird in Abschnitt 5.8 untersucht.




Abbildung 5.14 – Die Top-Level-Zielhierarchie des Fahrermodells.

5.6 Fahrermodell

Im Folgenden wird die Struktur und Arbeitsweise des Fahrermodells beschrieben. Dabei wird vor allem auf die für das Versuchsszenario und das AIE-Modell relevanten Aspekte eingegangen. Um die Darstellung übersichtlich zu halten sind Wahrnehmungsregeln in den Prozedurabschnitten nicht aufgeführt. Im Fahrermodell ist jedoch für jede Information aus der Umgebung eine entsprechende Wahrnehmungsregel vorhanden.

Die Aufgabenbeschreibung des Fahrermodells (s. Abbildung 5.14) spiegelt die drei Aufgaben wider, welche die Versuchspersonen zu bewältigen hatten (Lateralkontrolle, Longitudinalkontrolle, Number Read Back Task). In Prozedurabschnitt 5.1 sind die Produktionsregeln für das Top-Level-Ziel `driving` im CASCaS-Format aufgelistet. Mit dem Ziel `driving` wird die Simulation des Fahrermodells initialisiert. Nachdem die kognitive Architektur gestartet wurde, wartet das Fahrermodell, bis auch die Fahrsimulation gestartet ist. Sobald dies geschehen ist, werden `longitudinal_control`, `lateral_control` und `number_read_back_task` als Unterziele von `driving` aktiviert (rule 1). Sie sind während der gesamten weiteren Simulation aktiv und konkurrieren um die Ressource Aufmerksamkeit.

Für diese drei Ziele werden die über den [Lowest-Ordinal-Algorithmus](#) ermittelten Wertfaktoren verwendet, die auch für die Vorhersagen des SEEV-Modells in Abschnitt 5.3 genutzt wurden (s. Tabelle 5.2, S. 124). Für den ersten Versuchsblock werden daher die Wertfaktoren $v_{\text{lateral_control}}=2.0$, $v_{\text{longitudinal_control}}=1.0$ und $v_{\text{number_read_back_task}}=1.0$ verwendet.

Prozedurabschnitt 5.1 – Produktionsregeln des Top-Level-Ziels Driving

```

// Wait for driving simulator to get ready.
rule=1, goal=driving, type=regular
  Condition, simulation.started==1
  =>
    Goal, name=lateral_control, mode=persistent, value=v_lateral_control
    Goal, name=number_read_back_task, mode=persistent, value=v_number_read_back_task
    Goal, name=longitudinal_control, mode=persistent, value=v_longitudinal_control
    Skill, steering, start
  ;

/* Task description for longitudinal control, lateral control and NRBT task.*/
#include longitudinal_skill_control.proc
#include lateral_control.proc
#include number_read_back_task.proc
/* Setup and Shutdown routines to handle the interaction with the driving simulator */
#include start_simulation.proc
#include terminate_simulation.proc
  
```

5.6.1 Lateralkontrolle

Für die Lateralkontrolle wird im Fahrermodell eine modifizierte Version von Salvucci und Grays (2004) Zweipunktregler verwendet, den sie als Basis für ein Fahrermodell in ACT-R nutzten.

5.6.1.1 Wahrnehmung des Nah- und Fernbereichs

Der Zweipunktregler basiert auf einem kontrolltheoretischem Modell von Donges (1978), das von der grundlegenden Annahme ausgeht, dass Autofahrer für die Lateralkontrolle Informationen aus zwei visuellen Bereichen verwenden. Einer dieser Bereiche - der Nahbereich - liegt direkt vor dem Fahrzeug. Er ist nach Land und Horwood (1995) etwa 9 Meter vom Fahrzeug entfernt und gibt vor allem Aufschluss über die laterale Position des Fahrzeugs in der Spur. Der zweite Bereich - der Fernbereich - befindet sich in größerer Entfernung und liefert zusätzlich Informationen zum zukünftigen Verlauf der Straße. Grundlage für diese Annahme bilden unter anderem Experimente von Land und Horwood (1995) und Donges (1978). Land und Horwood zeigten, dass die Fahrqualität stark leidet, wenn dem Fahrer nur einer der Bereiche zur Verfügung steht. Da Autofahrer die meiste Zeit ihren Blick jedoch in den Fernbereich richten (Land und Lee, 1994; Kandil et al., 2009), gehen Salvucci und Gray davon aus, dass Informationen aus dem Nahbereich auch über die *periphere Sicht* wahrgenommen werden können. Eine spätere Studie, die speziell diese Hypothese mit einer größeren Gruppe an Versuchspersonen untersuchte, stützt die Annahme (Neumann und Deml, 2011). Horrey und Wickens (2004) führen dies darauf zurück, dass die Wahrnehmung der Eigenbewegung über den *ambienten Sinneskanal* auch im peripheren Sichtfeld gut ausgeprägt ist.

In Untersuchungen von Summala et al. (1996) wurde gezeigt, dass Autofahrer die Lateralkontrolle für eine kurze Zeit sogar ausschließlich mit Informationen aus der peripheren Wahrnehmung durchführen können. Dabei sollten Versuchsfahrer den Blickfokus durchgängig auf ein Aufgabendisplay innerhalb des Fahrzeugs richten, so dass sie für die Lateralkontrolle nur die periphere Wahrnehmung zur Verfügung hatten. Es zeigte sich, dass die Fahrer Informationen aus der peripheren Wahrnehmung für die Lateralkontrolle verwenden, auch wenn die Qualität der Lateralkontrolle dabei deutlich schlechter ist, als wenn die Fahrer den Blickfokus direkt auf die Straße richten.

Es wird in dieser Arbeit daher davon ausgegangen, dass für die Informationen des Fernbereichs der *fokale Sinneskanal* benötigt wird, während die Informationen im Nahbereich über den *ambienten Sinneskanal* aufgenommen werden und daher im *fovealen* und *peripheren Sichtfeld* wahrnehmbar sind.

5.6.1.2 Lateralkontrolle mit Nah- und Fernpunkt

Im Zweipunktregler von Salvucci und Gray (2004) wird der Fernbereich durch einen markanten Punkt im Fernbereich bestimmt. Dies kann je nach Situation der *Tangentenpunkt* einer Kurve, der Fluchtpunkt der Straße oder auch ein vorausfahrendes Fahrzeug sein. Der Fernpunkt beschreibt das Ziel, das der Fahrer innerhalb der nächsten ein bis zwei Sekunden erreichen möchte. Der Winkel θ_f zwischen dem Fernpunkt und der Fahrzeugausrichtung gibt somit die Abweichung zwischen gewünschter Fahrtrichtung und tatsächlicher Fahrtrichtung an (s. Abbildung 5.15) und wird direkt als eine der *Regelabweichungen* verwendet.

Zur Beschreibung des Nahbereichs verwenden Salvucci und Gray (2004) einen Punkt (Nahpunkt) im Zentrum der Fahrspur 6.2 m vor dem Fahrzeugzentrum. Der




Abbildung 5.15 – Winkeldefinitionen für den Regler zur Lateralkontrolle nach Salvucci und Gray (2004).

Winkel θ_n zwischen der Fahrzeugausrichtung und der Geraden zwischen Fahrzeug und dem Nahpunkt bestimmt die Abweichung des Fahrzeugs von der Spurmitte und wird als weitere Regelabweichung verwendet. Zur Beschreibung des Nahbereichs lassen sich alternativ auch der Abstand des Fahrzeugs zum Fahrbahnrand oder zur Spurmitte verwenden (Salvucci und Gray, 2004).

Die Reglerkomponenten, die sich auf θ_n beziehen, korrigieren somit den aktuellen Fehler in der Spurposition und werden als kompensatorische Elemente bezeichnet, während die Komponenten, die sich auf θ_f beziehen, versuchen den zukünftigen Fehler in der Spurposition zu minimieren. Sie werden als antizipatorische Elemente bezeichnet (Donges, 1978).

Der Winkel θ_n geht in die Reglerformel über ein P- und ein I-Glied ein, während der Winkel zum Fernpunkt θ_f lediglich über ein P-Glied berücksichtigt wird. Der Lenkwinkel φ ist die Stellgröße des Reglers, über die versucht wird, die Regelabweichungen auszugleichen. Daraus ergibt sich folgender Regler (vgl. Salvucci und Gray, 2004):

$$\varphi = k_f^P \theta_f + k_n^P \theta_n + k_n^I \int \theta_n dt \quad (5.2)$$

Der oben beschriebene Regler von Salvucci und Gray (2004) wurde für das in der vorliegenden Arbeit verwendete Fahrermodell als Skill (s. Abschnitt 2.3.6, S. 51) auf der autonomen Ebene implementiert. Er wird aktiviert, sobald das Ziel `lateral_control` aktiviert wird (s. Prozedurabschnitt 5.1). Allerdings erhält er nur neue Winkelinformationen, wenn diese auch von der Wahrnehmungskomponente wahrgenommen werden können. Dies bedeutet insbesondere, dass die Fahrqualität leidet, wenn der Fahrer nicht zur Straße schaut. Zur Beschreibung des Nahbereichs (θ_n) wurde anstelle des Winkels zwischen Nahpunkt und Fahrtrichtung der Abstand des Fahrzeugzentrums zur Fahrspurmitte verwendet.

5.6.1.3 Lenken ohne Fernpunkt

Salvucci (2001b, 2009) nutzte das ACT-R-Fahrermodell, um den Effekt von Ablenkung auf das Fahrverhalten vorherzusagen. Hierzu ließ er das Fahrermodell mit weiteren Aufgaben wie das Wählen einer Telefonnummer interagieren. Um sowohl die Fahraufgabe als auch die Nebenaufgabe zu bewerkstelligen, muss das Fahrermodell die Aufmerksamkeit auf die beiden Aufgaben aufteilen. Wenn die Aufmerksamkeit auf die Nebenaufgabe gerichtet ist, führt das Fahrermodell keine Lenkkorrekturen




Abbildung 5.16 – Blicke und Lenkbewegungen bei mittlerer Streckenschwierigkeit und niedriger Aufgabenrate der Versuchsperson 10.

mehr durch. Dadurch verschlechtert sich die Fahrqualität je stärker das Fahrermodell abgelenkt ist.

In einem ersten Schritt wurde dieses Vorgehen auch für das CASCaS-Fahrermodell verwendet. Simulationen in den kurvigen Strecken des in dieser Arbeit verwendeten Versuchsszenarios führten jedoch zu einer sehr instabilen Spurführung des Fahrzeugs. Das Lenkverhalten der Versuchspersonen unterschied sich deutlich von dem des Fahrermodells. In [Abbildung 5.16](#) ist beispielhaft für Versuchsperson 10 der Lenkwinkel über eine Strecke von 1,5 Kilometern bei mittlerer Streckenschwierigkeit und niedriger NRBT-Aufgabenrate aufgezeichnet. Während der Fahrer zur Straße schaut, ist der Wert des Lenkwinkels durch eine rote, durchgezogene Linie dargestellt, andernfalls durch eine grüne, gepunktete Linie. Es lässt sich gut erkennen, dass Lenkbewegungen durchgeführt wurden, während der Fahrer auf die Straße blickt, aber ebenso zu anderen Zeitpunkten während er nicht zur Straße schaut. Eine Kontrollstrategie, die nur aktiv ist, während der Fahrer zur Straße blickt, scheint hier daher nicht angebracht.

Tatsächlich ist bei dem für die Fahrversuche verwendeten Simulatorenaufbau davon auszugehen, dass den Versuchspersonen beim Blick auf das NRBT-Display oder auf die Geschwindigkeitsanzeige zumindest Informationen aus dem Nahbereich über die [periphere Wahrnehmung](#) zur Verfügung standen. Beide Informationsquellen liegen nur wenige Grad unterhalb des unteren Sichtbereichs zur Fahrbahn (s. [Abbildung 5.2](#)).

Um dem Rechnung zu tragen, wurden in der Lateralkontrolle des Fahrermodells zwei Modi eingeführt, die sich nach dem Zwei-Ebenen-Modell von [Donges \(2009\)](#) richten. Demnach ist das Fahrerlenkverhalten in zwei Ebenen unterteilt. Auf der Führungsebene findet die antizipatorische Regelung statt, bei der der Fahrer versucht einer selbstgewählten Sollspur zu folgen. Hierfür verwendet er Informationen aus dem Fernbereich. Auf der Stabilisierungsebene wird dagegen die kompensatorische Regelung mittels der Informationen aus dem Nahbereich durchgeführt. In dem Drei-Ebenen-Modell von [Rasmussen \(1983\)](#) ordnet [Donges \(2009\)](#) die Stabilisierung dem fertigkeitbasierten Verhalten zu, das in CASCaS auf der autonomen Ebene ausgeführt wird. Auf der Führungsebene lokalisiert Donges dagegen sowohl fertigkeitbasiertes Verhalten, als auch regelbasiertes Verhalten, welches in CASCaS auf der assoziativen Ebene ausgeführt wird.

Daher wurden für das Fahrermodell in CASCaS Aspekte der Lateralkontrolle auf beiden Ebenen umgesetzt. Dies ist in [Abbildung 5.17](#) dargestellt. Die Simulation der Lenkradbewegungen findet auf der autonomen Ebene basierend auf dem in [Gleichung 5.2](#) abgebildeten Reglers sowohl für die kompensatorische, als auch die antizipatorische Regelung statt. Wie in [Abschnitt 2.1](#) bereits erwähnt, wird die Wahrnehmung der Eigenbewegung als [präattentives Merkmal](#) über den [ambien-](#)

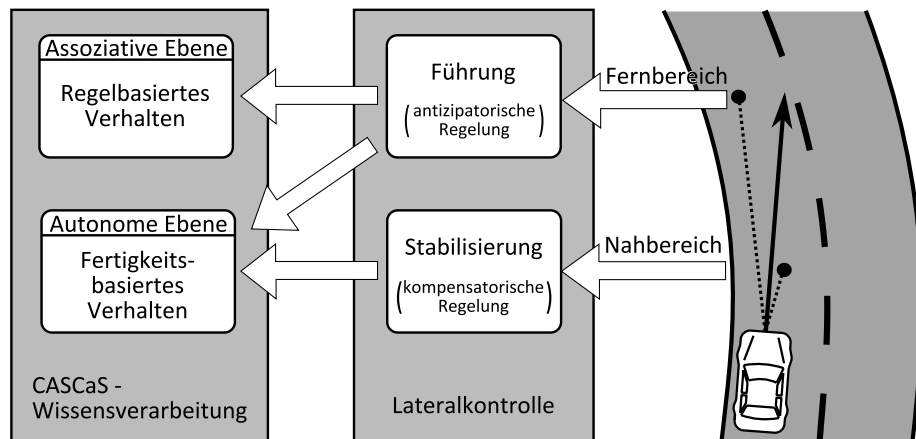


Abbildung 5.17 – Konzeptionelle Integration der kompensatorischen und antizipatorischen Aspekte der Lateralkontrolle in CASCaS (nach Donges, 2009).

ten Sinneskanal wahrgenommen. Um dem Rechnung zu tragen, nimmt das Fahrermodell auch während es auf die Geschwindigkeitsanzeige oder das NRBT-Display schaut den Abstand zum Fahrbahnrand wahr. Auf diese Weise kann das Fahrermodell weiterhin Lenkkorrekturen machen. Es kann jedoch in dieser Zeit nur auf einen kompensatorischen Mechanismus zurückgreifen, da ihm die Information aus dem Fernbereich fehlt. Somit reduziert sich in diesen Situationen die Lateralkontrolle auf folgenden PI-Regler:

$$\varphi = \tilde{k}_n^P \theta_n + \tilde{k}_n^I \int \theta_n dt \quad (5.3)$$

5.6.1.4 Stabilitätskriterien

Das ACT-R-Fahrermodell mit dem integrierten Zweipunktregler wurde von Salvucci (2001b, 2009) auch genutzt, um die Bearbeitung von Nebenaufgaben während des Fahrens zu untersuchen. Dem ACT-R-Fahrermodell ist ein Wechsel der Aufmerksamkeit von der Fahraufgabe zur Nebenaufgabe nur in sicheren Situationen erlaubt. Um sichere Situationen zu charakterisieren, gibt Salvucci ein Stabilitätskriterium für die kompensatorische Regelung und ein weiteres für die antizipatorische Regelung an, die beide erfüllt sein müssen, damit das Fahrermodell den Blick weg von der Straße richten kann.

Dieses Vorgehen wurde auch für das CASCaS-Fahrermodell in dieser Arbeit übernommen, wobei die Bewertung der Stabilitätskriterien auf der assoziativen Ebene geschieht. Das Stabilitätskriterium für die kompensatorische Regelung wird über die Abweichung von der Spurmitte definiert. Es ist erfüllt, wenn die Abweichung unterhalb eines Schwellenwertes σ_{lat} liegt. Das Stabilitätskriterium für die antizipatorische Regelung wird über die Zeit bis zum Überqueren der Spurmarkierung (TLC - Time to line crossing) definiert. Die TLC gibt die Zeit an, die das Fahrzeug in der momentanen Situation benötigt, um bei aktueller Geschwindigkeit über die rechte oder linke Spurmarkierung zu fahren. Liegt die TLC oberhalb eines Schwellenwertes σ_{lat} , so ist das Stabilitätskriterium erfüllt.

Im Prozedurabschnitt 5.2 sind die Produktionsregeln für die Lateralkontrolle abgebildet. Mit diesen Regeln wird die Überprüfung der Stabilitätskriterien auf der assoziativen Ebene durchgeführt. Durch das kontinuierlich aktive Ziel `lateral_control`

Prozedurabschnitt 5.2 – Produktionsregeln der Lateralkontrolle

```

/* When lateral_control is active, it guides the attention of the driver model,
 * so that it constantly monitors the road ahead. */
rule = 200001, name=lateral_control, type=regular
  Condition, (ego.position.lateral_deviation >  $\sigma_{lat}$ )
  ==>
  Goal, name=stabilize_car, value= $v_{lat}$ 
;

rule = 200002, name=lateral_control, type=regular
  Condition, (ego.position.lateral_deviation <  $-\sigma_{lat}$ )
  ==>
  Goal, name=stabilize_car, value= $v_{lat}$ 
;

rule = 200003, name=lateral_control, type=regular
  Condition, (ego.tlc <  $\tau_{lat}$ )
  ==>
  Goal, name=stabilize_car, value= $v_{lat}$ 
;

rule = 200301, type=reactive
  Condition, (ego.position.distance_lane_border < -0.25\,m)
  ==>
  Goal, name=lateral_control, value= $v_{lat}$ 
;

/* stabilize_speed is active as long as the driver model judges the current state as unstable. */
rule = 201001, name=stabilize_car, type=regular
  Condition, (ego.position.lateral_deviation >  $\sigma_{lat}$ )
  ==>
  GoalContinue
;

rule = 201002, name=stabilize_car, type=regular
  Condition, (ego.position.lateral_deviation <  $-\sigma_{lat}$ )
  ==>
  GoalContinue
;

rule = 201003, name=stabilize_car, type=regular
  Condition, (ego.tlc <  $\tau_{lat}$ )
  ==>
  GoalContinue
;

rule=201201, name=stabilize_car, type=waiting
  ==>
  GoalDone, stabilize_car
;

```

richtet das Fahrermodell seinen Blick immer wieder auf die Straße, um das Sicherheitskriterium zu überprüfen. Ist der Zustand der Lateralführung nicht sicher, so wird das Ziel `stabilize_car` aktiviert, das die visuelle Aufmerksamkeit solange auf die Straße richtet, bis sich das Fahrzeug in einem sicheren Zustand stabilisiert hat. Die Prozedur enthält eine reaktive Regel (200301). Diese wurde erst während der Evaluationsphase dem Modell hinzugefügt. Sie wird gefeuert, wenn das Fahrzeug eine Spurmarkierung bereits um 25 cm überschritten hat und sorgt dafür, dass die Aufmerksamkeit wieder auf die Lateralkontrolle gelenkt wird. Die 25 cm entsprechen der Breite des **Randstreifens**. Die Idee hinter dieser Regel ist, dass wenn der Fahrer in der Lage ist, Informationen zur lateralen Position über die **ambientale Wahrnehmung** im peripheren Blickfeld aufzunehmen, dann sollte er auch auf starke Abweichungen von der Spur reagieren können, wenn er zum Beispiel auf die Geschwindigkeitsanzeige schaut. Hinzugefügt wurde diese Produktionsregel jedoch erst während der Phase der Parameterschätzung (s. Abschnitt 5.7), da zahlreiche

Parameterkonstellationen zu instabilem Fahrverhalten führten. Dies wiederum bewirkte, dass das Fahrzeug die Straße häufiger verließ. Da diese Situationen die Parameterschätzung erschwerten, wurde die Produktionsregel 200301 hinzugefügt. Die Problematik wird in Abschnitt 5.7 näher erläutert.

5.6.2 Longitudinalkontrolle

Im Versuchsszenario sind keine vorausfahrenden Fahrzeuge, Hindernisse, Verkehrsschilder o.ä. enthalten. Daher beschränkt sich die Aufgabe der Längsführung in diesem Szenario darauf die Zielgeschwindigkeit von 100 km/h einzuhalten. Dennoch werden in diesem Fahrermodell zwei verschiedene Modi für die Längsführung aktiviert. Zu Beginn der Simulation beschleunigt das Modell auf die Zielgeschwindigkeit. Dies geschieht im Modus `start_up`, für den das gleichnamige Ziel als Unterziel der Longitudinalkontrolle aktiviert wird (s. Abbildung 5.18). Sobald die Zielgeschwindigkeit erreicht wurde, wechselt das Modell in den Modus `free_ride` und aktiviert hierfür das gleichnamige Ziel. All dies geschieht innerhalb der ersten 200 Meter des Szenarios, die aufgrund des unterschiedlichen Verhaltens während des Anfahrens weder für die experimentellen Versuchsfahrten noch für die Modellfahrten ausgewertet wurden.

An dieser Stelle soll nicht weiter auf die Moduswechsel eingegangen werden, da für die ausgewerteten Abschnitte der Simulation immer nur das Ziel `free_ride` aktiv ist. Es wird daher im Folgenden auch synonym zur Longitudinalkontrolle verwendet.

Das Grundprinzip der Längsregelung im `free_ride`-Modus folgt einem **Proportionalregler** von [Tampère \(2004\)](#), der innerhalb einer Verkehrsflusssimulation genutzt wird, um die Geschwindigkeit einzelner Fahrzeuge zu simulieren. Bei diesem Regler wird die Differenz zwischen Wunschgeschwindigkeit (v_t) und aktueller Geschwindigkeit (v) für die **Regelabweichung** verwendet. Tampères Modell simuliert das Fahrverhalten eines Fahrzeugs und bestimmt direkt dessen Geschwindigkeit. In der vorliegenden Arbeit soll jedoch das Verhalten des menschlichen Fahrers simuliert werden. Daher ist die **Stellgröße** nicht die Fahrzeuggeschwindigkeit, sondern die Gas- und Bremspedalstellung (g). Um den Regler entsprechend anzupassen, wird der gleiche Ansatz verfolgt wie bei dem Regler für Folgefahrtszenarien von [Boer et al. \(2005\)](#). Hierbei wird eine weitere Komponente in die Reglerformel integriert, die als **Steady-State-Funktion** (v_{ss}) bezeichnet wird:

$$g = c^P \cdot (v_t - v) + v_{ss}^{-1}(v_t) \quad (5.4)$$

Die Funktion v_{ss} stellt ein Modell der Fahrzeugdynamik dar. Als Wert liefert sie die Geschwindigkeit zurück, die das Fahrzeug schließlich in einem stabilen Zustand erreicht, wenn das Gaspedal konstant auf einer bestimmten Position gehalten wird.






Abbildung 5.18 – Die Modi `start_up` und `free_ride` als konkurrierende Unterziele der Longitudinalkontrolle .



(a) Gaspedalposition der Versuchsperson 4.



(b) Gaspedalposition bei Simulation des Fahrermodells.

Abbildung 5.19 – Beispielhafter Verlauf der Gaspedalposition für (a) Versuchsperson 4 und (b) dem Fahrermodell bei mittlerem Kurvenradius und hoher NRBT-Aufgabenrate.

Für das Fahrermodell wurde die Funktion an das in der Fahrsimulation verwendete Fahrzeugmodell angepasst. Realisiert ist sie als Lookup-Table.

Ebenso wie bei der Lateralkontrolle findet die Auswertung der Reglerformel und die Wahl der Gaspedalstellung auf der autonomen Ebene statt. Auf der assoziativen Ebene wird dagegen über den Schwellenwert σ_{long} bewertet, ob die Abweichung von der Zielgeschwindigkeit zu groß ist und die Geschwindigkeit daher stabilisiert werden muss. Anders als bei der Lateralkontrolle, erhält der Regler auf der autonomen Ebene jedoch keine Informationen aus der *peripheren Wahrnehmung*. Das bedeutet, dass die Gaspedalstellung nur angepasst werden kann, nachdem das Fahrermodell auf die Geschwindigkeitsanzeige geschaut hat, um die aktuelle Geschwindigkeit wahrzunehmen. Die Gaspedalposition wird somit nur sporadisch und nicht wie die Lenkradstellung kontinuierlich geändert. Dies deckt sich mit der Gaspedalbedienung der meisten Versuchspersonen. In *Abbildung 5.19* ist die Positionsänderung beispielhaft für Versuchsperson 4 und dem Fahrermodell zu sehen. Es fällt auf, dass bei der Versuchsperson der Wert häufig über mehrere Sekunden konstant ist und sich dann abrupt ändert. Da das Fahrermodell die Gaspedalstellung nur bei Blicken auf die Geschwindigkeitsanzeige ändert, weist es ein ähnliches Verhalten auf.

Die Struktur des Ziels `free_ride` ist in *Prozedurabschnitt 5.3* zu sehen. Der Aufbau ist analog zur Lateralkontrolle. Das kontinuierlich aktive Ziel `free_ride` sorgt dafür, dass das Fahrermodell die Geschwindigkeitsanzeige von Zeit zu Zeit betrachtet und greift über das Ziel `stabilize_speed` stabilisierend ein, wenn die Abweichung von der Zielgeschwindigkeit zu hoch ist ($> \sigma_{long}$).

Auch wenn die genaue Geschwindigkeit nur über die Geschwindigkeitsanzeige wahrgenommen werden kann, so sind Fahrer dennoch in der Lage die eigene Geschwindigkeit auch über andere Informationsquellen abzuschätzen. Durch die eigene Bewegung verändert sich das visuelle Bild der Umwelt. Diese Veränderung wird neben anderen Informationen, wie dem Fahrzeuggeräusch und der Fahrzeugbewegung, ge-

Prozedurabschnitt 5.3 – Produktionsregeln der Longitudinalkontrolle

```

// Stabilize speed if the deviation from the target speed
// is greater than the longitudinal stability criterion ( $\sigma_{long}$ )
rule=120001, goal=free_ride, type=regular
  Retrieve, target_velocity, ignoreAge
  Condition, (speedometer.value > target_velocity +  $\sigma_{long}$ )
  ==>
    Goal, name=stabilize_speed, value= $v_{long}$ , mode=continuous
  ;

rule=120001, goal=free_ride, type=regular
  Retrieve, target_velocity, ignoreAge
  Condition, (speedometer.value < target_velocity -  $\sigma_{long}$ )
  ==>
    Goal, name=stabilize_speed, value= $v_{long}$ , mode=continuous
  ;

// If speed > 120 km/h (33.3 m/s), it is detected in the visual flow of the peripheral view
// via the speed_estimation variable and the driver model switches to longitudinal control.
rule=120301, type=reactive
  Condition, (ego.speed_estimation > 33.3)
  ==>
    Goal, name=free_ride
  ;

// Stabilize speed, until the speed deviation is in an acceptable range
rule=121001, goal=stabilize_speed, type=regular
  Retrieve, target_velocity, ignoreAge
  Condition, (speedometer.value <= target_velocity -  $\sigma_{long}/2$ )
  ==>
  ;

rule=121002, goal=stabilize_speed, type=regular
  Retrieve, target_velocity, ignoreAge
  Condition, (speedometer.value >= target_velocity +  $\sigma_{long}/2$ )
  ==>
  ;

rule=121201, goal=stabilize_speed, type=waiting
  ==>
    GoalDone, stabilize_speed
  ;

```

nutzt um einen Eindruck der eigenen Geschwindigkeit zu bekommen (Panerai et al., 2001). Um die Geschwindigkeitswahrnehmung über den optischen Fluss zumindest im Ansatz nachzubilden, reagiert das Fahrermodell auf große Abweichungen (> 20 km/h) von der Zielgeschwindigkeit auch wenn es auf die Straße schaut, indem es die Aufmerksamkeit auf die Longitudinalkontrolle richtet (Regel 120301). Die Wahl dieses Schwellenwerts basiert auf einer Studie von Durkee und Ward (2011), bei der Versuchspersonen im Simulator eine Geschwindigkeit von 65 mph (~104,6 km/h) einhalten sollten, ohne die Geschwindigkeitsanzeige zur Verfügung zu haben. Dabei überschritten die Versuchspersonen die Zielgeschwindigkeit um etwa 20 km/h. Dieser Wert wurde in der vorliegenden Arbeit als Schwellenwert für das Fahrermodell gewählt, da die Zielgeschwindigkeit aus Durkee und Wards Studie ungefähr der hier verwendeten Zielgeschwindigkeit entspricht.

5.6.3 Number Read Back Task

Die Produktionsregeln zur Bearbeitung der Nebenaufgabe sind in Prozedurabschnitt 5.4 zu sehen. Das Ziel `number_read_back_task` ist kontinuierlich aktiv und sorgt dafür, dass das Fahrermodell von Zeit zu Zeit auf das NRBT-Display schaut. Mit der Produktionsregel 310001 prüft das Fahrermodell, ob eine Ziffernfolge auf

Prozedurabschnitt 5.4 – Produktionsregeln der NRBT-Aufgabe

```
// Check wether a new stimuli is presented on the NRBT screen
rule=310001, goal=number_read_back_task, type=regular
  Retrieve, number_read_back_task.last_task, ignoreAge
  Condition, (number_read_back_task.task_visible == 1)
  Condition, (number_read_back_task.last_task < number_read_back_task.current_task)
  =>
  Memorize, number_read_back_task.last_task, number_read_back_task.current_task
  Motor, number_read_back_task.reaction, number_read_back_task.task_count
  Goal, name=read_number
;

rule=311001, goal=read_number, type=regular
  Retrieve, number_read_back_task.number
  =>
  Vocal, '#number_read_back_task.number#', number=number_read_back_task.number, me
;
```

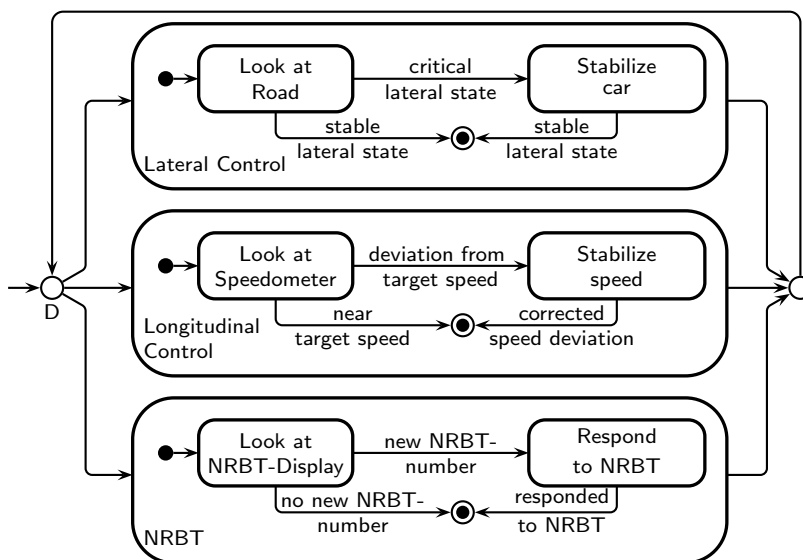


Abbildung 5.20 – UML-Zustandsdiagramm des Fahrermodells.

dem NRBT-Display angezeigt wird. Dies wird über die Variable `number_read_back_task.task_visible` kodiert. Wenn das Modell diese Ziffernfolge noch nicht bearbeitet hat (kodiert über `number_read_back_task.current_task`), drückt es über ein Motorkommando die NRBT-Reaktionstaste (`number_read_back_task.reaction`). Zudem aktiviert es das Ziel `read_number`. Für dieses Ziel richtet das Fahrermodell seinen Blick auf die Ziffernfolge und liest sie vor.

Der wichtigste Aspekt bei der Aufgabenprozedur ist, dass das Fahrermodell neue Ziffernfolgen erkennt und auf diese reagiert, damit diese als Ereignis wahrgenommen und in die Ereignisfunktion des Fahrermodells aufgenommen werden. Andere Aspekte der Modellierung sind abstrakt gehalten. Es wird zum Beispiel nicht modelliert, wie genau der Fahrer erkennt, dass eine neue Ziffernfolge präsentiert wird. Der Number Read Back Task bildet zusammen mit der Lateral- und Longitudinalkontrolle die drei Aufgaben, die in diesem Szenario um die Aufmerksamkeit konkurrieren. In Abbildung 5.20 sind sie in einer Übersicht als Zustandsdiagramm dargestellt.



Abbildung 5.21 – Umgebungstopologie des Fahrermodells.

5.6.4 Umgebungstopologie

Um die Blickbewegungen zwischen verschiedenen Informationsquellen zu simulieren, wurde auf Basis der Simulatorabmessungen eine einfache 3D-Topologie der Fahrerkabine erstellt (s. Abschnitt 2.3.3.1). Als Informationsquellen sind hierbei die Sicht durch die Windschutzscheibe auf die Straße, die Geschwindigkeitsanzeige, das Display in der Mittelkonsole, sowie Rück- und linker Außenspiegel definiert. Die Spiegel werden vom Fahrermodell jedoch nicht verwendet. In Abbildung 5.21 ist die von CASCaS gerenderte Topologie zu sehen.

5.7 Parameterschätzung der Lateral- und Longitudinalkontrolle

Zur Simulation des oben beschriebenen Fahrermodells fehlen noch einige Parameter für die Lateral- und Longitudinalkontrolle, die das Fahrverhalten essentiell bestimmen. Das sind einerseits die Verstärkungskonstanten k_f^P , k_n^P , k_n^I , \tilde{k}_n^P , \tilde{k}_n^I , c^P für die Lateral- und Longitudinalregler sowie die Schwellenwerte σ_{long} , σ_{lat} und τ_{lat} für die Stabilitätskriterien. Die Parameter sollten so gewählt sein, dass das Fahrverhalten des Fahrermodells möglichst gut das Verhalten der Versuchspersonen imitiert.

In einem ersten Schritt wurden initiale Parameter manuell durch iteratives Testen bestimmt, indem sinnvoll erscheinende Parameterkonstellationen ausprobiert wurden und auf Basis der resultierenden Simulationsergebnisse Änderungen an den Parametern vorgenommen wurden. Es zeigte sich rasch, dass die Parameter für die Lateralkontrolle mühsam zu bestimmen sind, da sich die Güte einer Parameterkonstellation nicht durch eine einzelne Simulation bestimmen ließ. Typischerweise unterscheiden sich zwei Simulationen des selben Modells, da einige Berechnungen in CASCaS probabilistische Elementen enthalten.

Zur Bestimmung der Parameter wurde daher ein automatisches Minimierungsverfahren genutzt. Ziel war es die Unterschiede in der Lateral- und Longitudinalkon-

trolle zwischen Versuchspersonen und Fahrermodell zu minimieren. Zur Bestimmung der Unterschiede wurden zwei Differenzmaße verwendet. Einerseits wurde die Differenz der Durchschnittsgeschwindigkeit \bar{v} des Fahrermodells zur Durchschnittsgeschwindigkeit der Versuchspersonen berechnet, und andererseits die Differenz der durchschnittlichen lateralen Abweichung \bar{d}_{Lat} von der mittleren Spurposition zwischen Fahrermodell und Versuchspersonen. Für das Minimierungsverfahren wird jedoch ein einzelner numerischer Wert als Differenzmaß benötigt. Die beiden Differenzmaße für \bar{v} und \bar{d}_{Lat} beschreiben unterschiedliche Größen und lassen sich nicht direkt miteinander vergleichen. Daher wurden \bar{v} und \bar{d}_{Lat} für jede Versuchsperson einzeln berechnet, so dass sich für beide Maße jeweils eine Verteilung für die experimentellen Werte ergab. Nach einer Simulation des Fahrermodells wurden \bar{v} und \bar{d}_{Lat} ebenfalls berechnet und über eine **Z-Transformation** anhand der experimentellen Verteilung standardisiert. Die z -Werte lassen sich direkt vergleichen, so dass das Differenzmaß nun aus der Summe ihrer Beträge gebildet wurde. Da die Stabilität der Lateralkontrolle sehr sensitiv auf Parameteränderungen reagierte, wurden die z -Werte für \bar{d}_{Lat} dreifach gewichtet, so dass sich folgendes Differenzmaß ergibt: $3 \cdot |z_{\bar{d}_{Lat}}| + |z_{\bar{v}}|$.

Als Minimierungsverfahren wurde der **Stochastic Model Reference Adaptive Search (SMRAS)**-Algorithmus (Hu et al., 2008) gewählt, der bei stochastischen Optimierungsproblemen verwendet wird. Da die Fahrsimulationssoftware nur Echtzeitsimulationen durchführen kann, ist die Auswertung eines Datenpunktes sehr zeitaufwendig. Daher wurden die Parameterkonstellationen jeweils nur für zwei Versuchsbedingungen getestet. Zum einen wurde die kritischste Situation mit schwieriger Strecke und hoher NRBT-Aufgabenrate gewählt, damit das Fahrermodell in der Lage ist, diese Extremsituation zu bewältigen. Zum anderen wurde die gleiche Situation mit leichter Streckenbedingung gewählt, um zu vermeiden, dass eine Überanpassung an die schwierige Strecke auftritt.

Bei der Suche nach einer geeigneten Parameterkonstellation sind Lerneffekte durch das AIE-Modell nicht erwünscht, da die hierfür benötigte Trainingsphase die Simulationszeit erheblich verlängert hätte. Daher wurde das Fahrermodell mit vorab trainierten **Ereignisfunktion** initialisiert. Allerdings ist das Fahrermodell ohne die benötigten Parameter noch nicht vollständig und es können somit auch keine Ereignisfunktionen vorab trainiert werden. Um dem Problem zu begegnen, wurde für das Training der Ereignisfunktionen die Parameterkonstellation verwendet, die sich während der manuellen Optimierung als gut erwiesen hatte. Die dabei erzeugten Ereignisfunktionen wurden für die weitere automatische Parameterschätzung verwendet.

Der **SMRAS**-Algorithmus arbeitet iterativ mit Generationen von Parametern. Jede Generation besteht aus einer Menge von Parameterkonstellationen. Die Anzahl an Simulationen pro Parameterkonstellation steigt bei späteren Generationen immer weiter an. Begonnen wurde mit jeweils zwei Simulationen für die beiden ausgewählten Versuchsbedingungen bei einer Wachstumsrate von 0.05 pro Generation ($M_0 = 2, \alpha_M = 0.05$, vgl. (Hu et al., 2008)).

Als Parameter für die Lateral- und Longitudinalkontrolle ergaben sich schließlich:

k_f^P	k_n^P	k_n^I	\tilde{k}_n^P	\tilde{k}_n^I	c^P	σ_{long}	σ_{lat}	τ_{lat}
0.239	0.051	$3.03 \cdot 10^{-5}$	1.442	$5.91 \cdot 10^{-3}$	0.032	0.107	0.898	3.2

Tabelle 5.9 – Die Parameter für die Lateral- und Longitudinalkontrolle.

Insbesondere zu Beginn der Parametersuche wurden häufig ungeeignete Parameterkonstellationen gewählt, die dazu führten, dass das Fahrzeug zum Teil weit von der Spur abkam. Kleine Abweichungen von der Spur stellten kein großes Problem dar, da sie leicht von der Lateralkontrolle korrigiert werden konnten. Spätestens jedoch wenn das Fahrzeug das **Bankett** der Straße verließ, fand das Fahrermodell normalerweise nicht mehr in einen stabilen Zustand zurück. Um die abrupten Höhenunterschiede beim Zurück-Lenken auf das Bankett sicher zu meistern, ist ein anderes Lenkverhalten erforderlich, als es durch den implementierten Regler für die Lateralkontrolle gegeben ist (Black und Wagner, 2011).

Ob ein Fahrzeug die Straße verlässt, hängt jedoch nicht ausschließlich von den in Tabelle 5.9 aufgelisteten Parametern ab, sondern auch vom Blickverhalten der Versuchsperson und der Interaktion mit der Nebenaufgabe. Bei langen **Blickablenkungsdauern** von der Straße im Bereich einer Krümmungsänderung der Strecke ist die Gefahr besonders hoch. Das Fahrermodell kann in einem Simulationslauf durchaus in eine solche kritische Situation gelangen und von der Straße abkommen, während es in einem weiteren Simulationslauf bei gleicher Parameterkonstellation in keine kritische Situation gerät. Problematisch ist dabei, dass sich die Differenzwerte für das Minimierungsverfahren in den beiden Simulationen stark unterscheiden. Eine hohe Varianz der Differenzwerte für dieselbe Parameterkonstellation erschwert jedoch die Parameterschätzung erheblich.

Insgesamt gestaltete sich die Parameterschätzung mittels automatischer Minimierungsverfahren als schwierig, da aufgrund der verwendeten Simulationssoftware ein Simulationslauf sehr zeitaufwendig ist, und ein einzelner Simulationslauf nicht ausreicht, um die Güte einer Parameterkonstellation zu bewerten. Zudem behindert der Lernprozess des AIE-Modells eine präzise Parameterschätzung.

5.8 Simulationsergebnisse

Mit den ermittelten Parametern wurde das Fahrermodell in verschiedenen Varianten ausgeführt. Hierzu wurde es in den gleichen Szenarien simuliert, die auch die Versuchspersonen durchfahren haben. Das Verhalten des Fahrermodells wird einerseits mit dem Verhalten der Versuchspersonen verglichen. Andererseits werden verschiedene Varianten des AIE-Modells verwendet und die dabei erzielten Ergebnisse untereinander verglichen.

Im Folgenden werden die Ergebnisse der Simulation betrachtet und das Verhalten des Fahrermodells mit dem Verhalten der Versuchspersonen verglichen. Zuerst werden die Ergebnisse beschrieben, die mit der bisherigen Aufmerksamkeitssteuerung von **CASCaS** erzielt wurden, um später bei den Ergebnissen, die mit dem **AIE-Modell** erzielt wurden, beurteilen zu können, welche Verhaltensaspekte durch das AIE-Modell erzeugt wurden und welche durch die anderen Komponenten von **CASCaS**. Analog zu den Modellvariationen im vorherigen Kapitel werden verschiedene Varianten des AIE-Modells diskutiert.

Einige Ergebnisse, die beim Vergleich des Blickverhaltens zwischen Fahrermodell und Versuchspersonen erzielt wurden, wurden bereits in (Wortelen et al., 2013a) vorgestellt. Vergleiche bezüglich des Fahrverhaltens wurden in (Wortelen et al., 2013b) präsentiert.

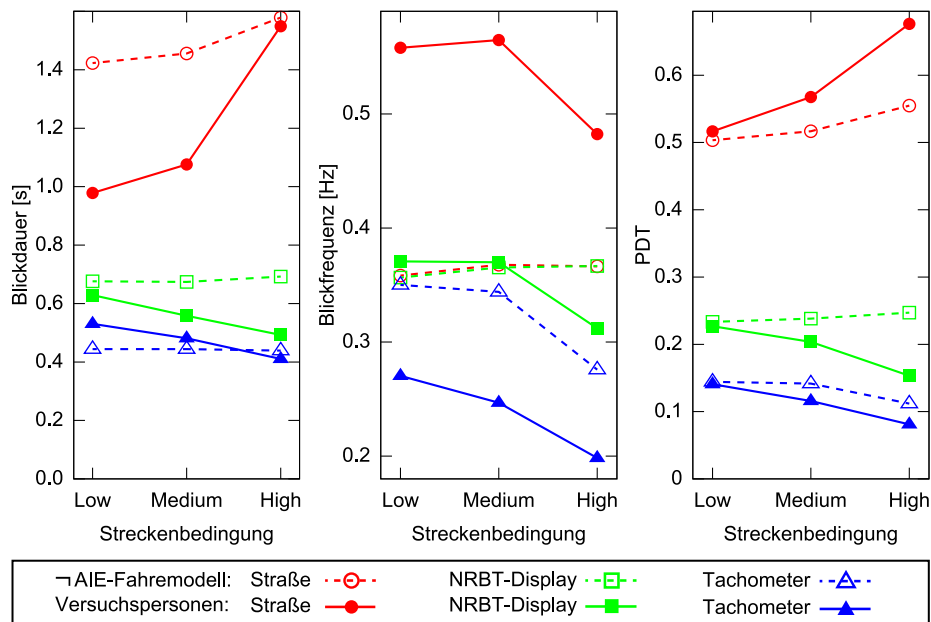


Abbildung 5.22 – Blickverhalten des ¬AIE-Fahrermodells und der Versuchspersonen bei unterschiedlicher Streckenschwierigkeit.

5.8.1 Simulation ohne AIE-Modell

Um den Effekt, den das AIE-Modell auf das Verhalten des Fahrermodells hat, zu demonstrieren, wurden zuerst Simulationen ohne AIE-Modell durchgeführt. Analog zum Agenten für Senders' Aufgabe, wird diese Variante als ¬AIE-Fahrermodell bezeichnet.

Insgesamt wurde jede Versuchsbedingung 20-mal simuliert. Das Blickverhalten des ¬AIE-Fahrermodells ähnelt stark dem Blickverhalten des ¬AIE-Agenten für Senders' Aufgabe. Die Blicke des Fahrermodells wanderten immer in der Reihenfolge von einer Informationsquelle zur nächsten, in der die entsprechenden Ziele der Zielagenda hinzugefügt wurden: Straße → NRBT-Display → Tachometer. Für das ¬AIE-Fahrermodell haben weder die [Aufgabenpriorisierungen](#) noch die [Ereignisraten](#) einen Einfluss auf die Aufmerksamkeitssteuerung.

Es zeigten sich keine Verhaltensunterschiede bei unterschiedlicher Priorisierung der Aufgaben. Bei unterschiedlichen Aufgabenraten der Nebenaufgabe zeigte sich lediglich ein kleiner Effekt in der Blickdauer zum NRBT-Display. Es wurden häufiger Aufgaben auf dem NRBT-Display angezeigt und damit auch häufiger vom Fahrermodell bearbeitet. Für das Ablesen der Nummern vom Display benötigt das Fahrermodell etwas Zeit. Daher war die durchschnittliche Blickdauer zum NRBT-Display bei hoher NRBT-Ereignisrate geringfügig höher.

Ein deutlicher Effekt auf das Blickverhalten zeigte sich lediglich bei unterschiedlichen Streckenbedingungen, da bei der schwierigen Strecke das Fahrermodell den Blick länger auf die Straße richtet, um das Fahrzeug zu stabilisieren. Dieser Effekt ist in [Abbildung 5.22](#) zu sehen. Dort ist das Blickverhalten der Versuchspersonen und des ¬AIE-Fahrermodells in Abhängigkeit von der Streckenbedingung zu sehen. Die Blickdauer zur Straße steigt mit dem Schwierigkeitsgrad der Strecke an, während sich die Blickdauern zu den anderen Informationsquellen nicht verändern. In dieser Grafik ist gut zu erkennen, dass das ¬AIE-Fahrermodell bereits einige

wichtige Aspekte des Blickverhaltens simuliert. Wie bei den Versuchspersonen haben die Blicke zur Geschwindigkeitsanzeige die kürzeste Dauer, gefolgt von den Blicken zum NRBT-Display und schließlich den Blicken zur Straße. Die Blicke zur Geschwindigkeitsanzeige sind die kürzesten, da lediglich die Position des Geschwindigkeitszeigers wahrgenommen werden muss. Dagegen sind die Blicke zum NRBT-Display unterschiedlich lang, je nachdem ob eine neue Aufgabe angezeigt wird oder nicht. Wird eine neue Aufgabe angezeigt, so müssen die Ziffern abgelesen werden. Dies benötigt zusätzliche Zeit. Die langen Blicke zur Straße werden dagegen vor allem zur Stabilisierung des Fahrzeugs benötigt. Allerdings überschätzt das Fahrermodell die Blickdauern zum NRBT-Display und zur Straße um durchschnittlich 121 ms bzw. 285 ms im Vergleich zu den Versuchspersonen.

Mit zunehmender Streckenschwierigkeit zeigte sich zudem ein Problem der \neg AIE-Variante des Fahrermodells immer stärker. Aufgrund der festen Blickreihenfolge, ist die [Blickablenkungsdauer](#) für die Blicke zur Straße sehr groß, da das Modell zwischen zwei Blicken zur Straße immer sowohl auf das Tachometer, als auch auf das NRBT-Display schaute.

Dies führte dazu, dass in dieser Zeit größere Abweichungen in der lateralen Position des Fahrzeugs entstanden. Dadurch wurde auch häufiger die in Abschnitt 5.6.1 angesprochene Produktionsregel 200301 gefeuert, die auf diese Abweichungen reagiert, um die Aufmerksamkeit wieder auf die Straße zu richten. Dies zeigt sich bei den Blickfrequenzen des Fahrermodells (s. Abbildung 5.22, Mitte). Es wäre zu erwarten, dass die Blickfrequenzen zu allen Informationsquellen nahezu identisch sind, da der Blick des Fahrermodells in fester Reihenfolge die Informationsquellen besucht und damit jede Informationsquelle gleich häufig betrachtet wird. Für die Blicke zur Straße und zum NRBT-Display trifft dies auch zu. Die Blickfrequenz zur Geschwindigkeitsanzeige nimmt jedoch mit steigender Streckenschwierigkeit ab. Der Grund hierfür liegt darin, dass die Blickreihenfolge durch das Feuern der Produktionsregel 200301 unterbrochen wird und vom Display der Nebenaufgabe direkt wieder auf die Straße gerichtet wird.

Der Unterschied zwischen dem Blickverhalten des Fahrermodells und dem der Versuchspersonen, der durch die starre Blickreihenfolge des Fahrermodells erzeugt wird, manifestiert sich deutlich beim Vergleich der [Transitionswahrscheinlichkeiten](#). Bei drei Informationsquellen lassen sich insgesamt sechs gerichtete [Transitionswahrscheinlichkeiten](#) beobachten. In diesem Szenario sind das:

- | | |
|--|--|
| 1. Straße \rightarrow NRBT Display | 4. NRBT Display \rightarrow Straße |
| 2. NRBT Display \rightarrow Tachometer | 5. Tachometer \rightarrow NRBT Display |
| 3. Tachometer \rightarrow Straße | 6. Straße \rightarrow Tachometer |

Für die 12 Versuchsbedingungen ergibt dies insgesamt 72 verschiedene Messwerte für die Transitionswahrscheinlichkeiten. In Abbildung 5.23 sind die gerichteten Transitionswahrscheinlichkeiten zwischen allen Informationsquellen des \neg AIE-Fahrermodells für alle Versuchsbedingungen im direkten Vergleich zu den Transitionswahrscheinlichkeiten der Versuchspersonen aufgetragen. Es zeigt sich ein ähnliches Bild wie bei den Transitionswahrscheinlichkeiten des \neg AIE-Agenten für Senders' Aufgabe (s. Abbildung 4.6, S. 100). Während die Wahrscheinlichkeiten bei den Versuchspersonen sehr unterschiedlich ausfallen, gruppieren sie sich beim \neg AIE-Fahrermodell um die Werte 0 und 0,33. Die drei Transitionen, die sich in der Blickreihenfolge des \neg AIE-Fahrermodells wiederfinden (Straße \rightarrow NRBT-Display \rightarrow Tachometer) haben in allen Versuchsbedingungen einen Wert von ungefähr $1/3$, während alle anderen einen Wert von ungefähr 0 haben. Die Abweichungen von diesen Werten kommen auch hier durch das Feuern der Produktionsregel 200301




Abbildung 5.23 – Gerichtete Transitionswahrscheinlichkeiten der Versuchspersonen im Vergleich zu denen des \neg AIE-Fahrermodells. Aufgetragen sind die Wahrscheinlichkeiten für jede Versuchsbedingung und jede Blicktransition zwischen einer der drei Informationsquellen.

zustande, da sich durch Anwendung dieser Produktionsregel die Blickreihenfolge ändert. Die Grafik zeigt, dass die Blicksequenzen des \neg AIE-Fahrermodells nichts mit denen der Versuchspersonen gemein haben ($r = -0.041$).


Das Fahrverhalten des \neg AIE-Fahrermodells ist, wie bereits erwähnt, sehr instabil und deutlich schlechter als das der Versuchspersonen. Dies gilt insbesondere im Hinblick auf die Lateralkontrolle. Das schlechte Fahrverhalten ist zum großen Teil ein Resultat des starren Blickverhaltens des Fahrermodells und wird hier nicht weiter betrachtet. Der Vollständigkeit halber sind die ermittelten Kenngrößen zum Fahrverhalten analog zu den Werten, die für die weiteren untersuchten Varianten des Fahrermodells aufgezeichnet wurden, im Anhang in Tabelle C.7 aufgelistet.

5.8.2 AIE⁺-Fahrermodell

In einem zweiten Simulationssetup wurde das Fahrermodell mit aktiviertem AIE-Modell simuliert, das die Wert- und Erwartungsparameter additiv kombiniert. Ansonsten war das Fahrermodell identisch zum \neg AIE-Fahrermodell. Im weiteren Verlauf wird es als AIE⁺-Fahrermodell bezeichnet.

Jede Versuchsbedingung wurde 25-mal hintereinander simuliert. Dies entspricht jeweils einer Simulationszeit von ungefähr 125 Minuten. Die ersten 50 Minuten wurden zum Trainieren der Ereignisfunktion verwendet. Lediglich die verbleibenden 75 Minuten wurden ausgewertet. Dies wurde für jede der 12 Versuchsbedingungen jeweils 5-mal durchgeführt. Das ergab eine Gesamtausführungszeit von etwa 5-6 Tagen.

Im Folgenden wird nun das Verhalten des AIE⁺-Fahrermodells mit dem Verhalten der Versuchspersonen verglichen. Das Hauptaugenmerk liegt dabei auf dem Blickverhalten, da es die mentale Aufmerksamkeit reflektiert (*Eye-Mind-Assumption*). Anschließend wird kurz auf die Auswirkung der unabhängigen Variablen auf die Qualität der Fahrzeugführung und die Bearbeitung der Nebenaufgabe eingegangen.



(a) Korrelation der prozentualen Blickverweilzeiten

(b) Korrelation der Blickfrequenzen

Abbildung 5.24 – Vergleich der prozentualen Blickverweilzeiten und Blickfrequenzen zwischen Versuchspersonen und AIE⁺-Fahrermodell für alle 12 Versuchsbedingungen.

5.8.2.1 Blickverhalten

Ein Vergleich der PDTs und Blickfrequenzen des AIE⁺-Fahrermodells gegenüber den Werten der Versuchspersonen findet sich in Abbildung 5.24 für alle 12 Versuchsbedingungen. Die Modellanpassungsgüte bezüglich der PDTs ist ähnlich gut wie beim SEEV-Modell. Für einen Vergleich zum SEEV-Modell können nur die PDTs verwendet werden, da das SEEV-Modell lediglich diese vorhersagt. Alle anderen Kenngrößen, die im weiteren Verlauf zusätzlich betrachtet werden, werden nur durch das AIE-Fahrermodell vorhergesagt.

In Tabelle 5.3 wurden bereits die Vorhersagen des SEEV-Modells aufgelistet. Die Modellanpassung an die experimentellen Daten (Tabelle 5.8, S. 137) ist gut. Das SEEV-Modell erklärt einen großen Anteil der Variabilität der PDTs ($R^2 = 0.959$) mit leichten absoluten Fehlern (RMSD = 0.058).

Das AIE⁺-Fahrermodell erreicht eine ähnlich hohe Korrelation ($R^2 = 0.958$), wobei die absoluten Fehler etwas geringer sind (RMSD = 0.045). Somit erzielen in diesem Anwendungsfall beide Modelle ähnlich gute Vorhersagen der prozentualen Blickverteilung.

Ein Vorteil des AIE-Modells besteht nun darin, dass es in eine kognitive Architektur eingebettet ist, mit der sich weitere Kenngrößen des Blickverhaltens ermitteln lassen. So wird die PDT durch die durchschnittliche Blickfrequenz und Blickdauer bestimmt. Im Folgenden wird vornehmlich auf die Blickfrequenz eingegangen, da das AIE-Modell diese durch die Zielauswahl direkt beeinflusst. Die Blickdauer hängt dagegen stärker von der Zeit ab, die benötigt wird, um die jeweiligen Informationen aus der Informationsquelle zu extrahieren, und von der Art und Weise, in der der Fahrer mit der Informationsquelle interagiert. Es sei jedoch darauf hingewiesen, dass sich die beiden Aspekte nicht unabhängig voneinander betrachten lassen. So könnte man erwarten, dass eine Erhöhung der Ereignisrate in einer Informationsquelle bei Verwendung AIE-Modells zu einer erhöhten Blickfrequenz zu

eben dieser Informationsquelle führt. Bei Informationsquellen mit einer hohen PDT kann aber auch der gegenteilige Effekt auftreten, da die Wahrscheinlichkeit steigt, dass das selbe Ziel mehrmals hintereinander ausgewählt wird, ohne dass der Blickfokus dabei die Informationsquelle verlässt. Damit steigt die Blickdauer, während die Blickfrequenz zu dieser Informationsquelle sinkt. Dieser Zusammenhang wird im weiteren Verlauf noch deutlicher.

In Abbildung 5.24(b) ist der Vergleich der mittleren Blickfrequenzen zwischen dem AIE⁺-Fahrermodell und den Versuchspersonen dargestellt. Es zeigt sich eine gute Übereinstimmung im Trend ($R^2 = 0.878$). Allerdings sind die Ergebnisse insgesamt etwas schlechter als bei den PDTs. Neben des leicht geringeren Korrelationskoeffizienten zeigt auch die Regressionsgerade lediglich eine Steigung von 0.759. Im Optimalfall sollte die Steigung 1 betragen. Insbesondere hohe Blickfrequenzen werden vom Fahrermodell leicht unterschätzt.

Im Folgenden wird das Blickverhalten im Detail betrachtet.

5.8.2.1.1 Prozentuale Blickverweilzeiten

In Abbildung 5.25 sind die prozentualen Blickverweilzeiten des AIE⁺-Fahrermodells (gestrichelte Linien) zusammen mit den empirisch ermittelten Ergebnissen (durchgezogenen Linien) in Abhängigkeit der manipulierten Variablen zu sehen. Das linke und mittlere Diagramm zeigen den Effekt, den die unterschiedlichen Ereignisraten der Lateralkontrolle bzw. des NRBT auf die PDTs haben.




Abbildung 5.25 – Effekte der unabhängigen Variablen auf die prozentualen Blickverweilzeiten der drei Informationsquellen. Daten der Versuchspersonen sind durch durchgezogene Linien dargestellt, Daten des AIE⁺-Fahrermodells als gestrichelte Linien.

Es lässt sich ein klarer Zusammenhang zwischen den Trends der experimentellen Daten und den Trends des Fahrermodells erkennen. Die Erhöhung der Ereignisrate einer Informationsquelle führt jeweils zur Erhöhung der PDT für diese Informationsquelle, während die PDTs für die anderen Informationsquellen entsprechend abnehmen. Allerdings ist der Effekt der Ereignisraten beim Fahrermodell fast durchgängig weniger stark ausgeprägt als bei den empirischen Daten der Versuchspersonen. Dies zeigt sich noch stärker bei der Manipulation der [Aufgabenpriorität](#). Alle als signifikant ermittelten Effekte werden vom AIE⁺-Fahrermodell konsistent wiedergegeben, allerdings in geringerer Ausprägung. Bei den nicht signifikanten Unterschieden sind die Trends zum Teil sogar gegenläufig.

Im Gegensatz zum SEEV-Modell lassen sich mit dem AIE-Modell diese Unterschiede im Detail beleuchten, da die Blicksequenzen tatsächlich simuliert werden. Wie bereits erwähnt, resultiert die PDT aus der durchschnittlichen Blickfrequenz und der durchschnittlichen Blickdauer, wobei eine starke Interaktion der Blickdauern und -frequenzen zwischen allen Informationsquellen besteht. Da das AIE-Modell nicht den [Datenakquisealgorithmus](#) beschreibt, der lediglich Einfluss auf die Dauer einzelner Blicke hat, sondern über die Zielauswahl den [Ablaufplanungsalgorithmus](#) beschreibt, der maßgeblich die Blickfrequenzen bestimmt, werden im Folgenden zunächst die Blickfrequenzen betrachtet. Da jedoch die Blickfrequenzen und die durchschnittlichen Blickdauern nicht vollständig unabhängig voneinander sind, wird später auch auf die Blickdauern eingegangen.

5.8.2.1.2 Blickfrequenzen

Der Vergleich der experimentell beobachteten Blickfrequenzen und der durch das AIE⁺-Fahrermodell erzeugten Blickfrequenzen ist für die Manipulation jeder unabhängigen Variable in [Abbildung 5.26](#) zu sehen. Die Modellanpassungsgüte der Blickfrequenzen weist Unterschiede zur Modellanpassungsgüte der PDTs auf, ist jedoch grundsätzlich gut. Ein interessanter Aspekt ist im linken Diagramm von [Abbildung 5.26](#) zu sehen. In [Abschnitt 5.5.1](#) wurde gezeigt, dass sich bei der Streckenbedingung nur ein signifikanter Effekt zwischen der mittleren und der schweren Bedingung zeigte, jedoch nicht zwischen der leichten und der mittleren. In [Abbildung 5.26](#) ist gut zu erkennen, dass auch das Fahrermodell einen größeren Effekt zwischen der mittleren und schweren Bedingung simuliert als zwischen der leichten und mittleren.

In [Abbildung 5.24](#) wurde bereits dargestellt, dass die Korrelation der Blickfrequenzen geringer als bei den prozentualen Blickverweilzeiten ist und auch der Verlauf der Korrelationsgerade schlechter ist. Die absoluten Abweichungen lassen sich aufgrund der unterschiedlichen Einheiten und Wertebereiche nicht direkt vergleichen. Die RMSD beträgt bei den Blickfrequenzen 0.081 Hz (PDTs: 0.045). Ein Vergleich der [Abbildungen 5.25](#) und [5.26](#) erweckt den Anschein, dass die absoluten Abweichungen bei den Blickfrequenzen höher sind. Im Verhältnis zu den beobachteten Mittelwertunterschieden zwischen den Versuchsbedingungen trifft dies auch zu. Setzt man die Abweichung jedoch in Relation zur Varianz der Versuchspersonenwerte, so ändert sich dieses Bild. Auf Basis der Versuchspersonendaten wurde eine entsprechende Standardisierung mittels [Z-Transformationen](#) für die durchschnittlichen PDT- und Blickfrequenzwerte des Fahrermodells in jeder Versuchsbedingung vorgenommen. Die Beträge der Z-Werte wurden über alle Versuchsbedingungen und alle Informationsquellen gemittelt. Der durchschnittliche absolute Z-Wert für die PDTs ist mit $|z| = 0.609$ Standardabweichungen etwas größer als bei den Blickfrequenzen mit $|z| = 0.556$ Standardabweichungen.

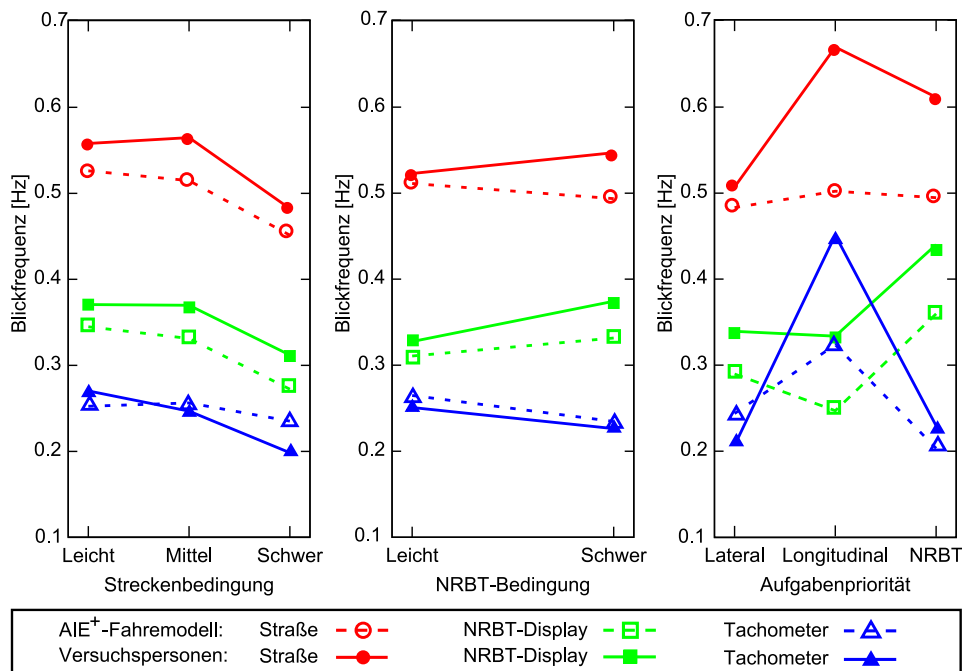


Abbildung 5.26 – Effekte der unabhängigen Variablen auf die Blickfrequenzen zu den drei Informationsquellen. Daten der Versuchspersonen sind als durchgezogene Linien dargestellt, Daten des AIE⁺-Fahrermodells als gestrichelte Linien.

Bei der Abweichung der absoluten Werte fällt zudem auf, dass das AIE⁺-Fahrermodell die Blickfrequenzen zur Straße und zum NRBT-Display systematisch unterschätzt. Dies lässt darauf schließen, dass die Blickdauern des Fahrermodells länger sind als bei den Versuchspersonen. Bevor jedoch auf die Blickdauern weiter eingegangen wird, werden im Folgenden die Transitionswahrscheinlichkeiten betrachtet, die eng mit den Blickfrequenzen zusammenhängen.

5.8.2.1.3 Transitionswahrscheinlichkeit

In Abbildung 5.27 sind die im Experiment gemessenen Transitionswahrscheinlichkeiten der Versuchspersonen den durch das AIE⁺-Fahrermodell ermittelten Werten gegenübergestellt. Das Fahrermodell erreicht dabei eine hohe Korrelation zu den empirischen Werten ($R^2 = 0.935$). Die erzielten Werte sind eine deutliche Verbesserung gegenüber den Werten, die ohne Verwendung des AIE-Modells erzielt wurden (s. Abbildung 5.23, S. 153). Dies deutet darauf hin, dass auch die vom AIE⁺-Fahrermodell erzeugte Blicksequenz der typischen Blicksequenz eines Fahrers entspricht.

5.8.2.1.4 Blickdauern

Auch wenn das AIE-Modell die Dauern einzelner Fixationen nicht beeinflusst, so lassen sich dennoch einige Effekte bezüglich der Blickdauern beobachten. Dabei lassen sich auch einige Probleme bei der hier vorgestellten Blicksimulation identifizieren. In Abbildung 5.28 sind analog zu den PDTs und Blickfrequenzen die durchschnittlichen Blickdauern für die Manipulation der unabhängigen Variablen dargestellt.




Abbildung 5.27 – Vergleich der Transitionswahrscheinlichkeiten. Abgebildet sind die gerichteten Transitionswahrscheinlichkeiten für alle Informationsquellen und alle Versuchsbedingungen vergleichend aufgetragen zwischen den Versuchspersonen und dem AIE⁺-Fahrermodell.




Abbildung 5.28 – Effekte der unabhängigen Variablen auf die Blickdauern zu den drei Informationsquellen. Daten der Versuchspersonen sind durch durchgezogene Linien dargestellt, Daten des AIE⁺-Fahrermodells als gestrichelte Linien.

Das AIE⁺-Fahrermodell gibt die Datentrends nicht so gut wieder wie bei den PDTs und Blickfrequenzen. Dennoch finden sich auch einige Gemeinsamkeiten. So wird die grundsätzliche Rangordnung der Blickdauern zu den drei Informationsquellen vom Fahrermodell reproduziert. Wie schon beim –AIE-Fahrermodell beschrieben (Abschnitt 5.8.1), ergibt sich diese Rangfolge durch die Modellierung der einzelnen Aufgaben.

Bei der Manipulation des Streckenverlaufs lässt sich zudem eine gute Trendübereinstimmung für die Blickdauern zur Straße beobachten. Mit steigender Streckenschwierigkeit steigt die Blickdauer an. Dabei ist der Anstieg zwischen der leichten und mittleren Streckenbedingung geringer, als zwischen der mittleren und schweren Streckenbedingung. Dies lässt sich sowohl bei den Versuchspersonen, als auch beim Fahrermodell beobachten. Dieser Effekt zeigte sich im Ansatz bereits für das –AIE-Fahrermodell, allerdings ist er beim AIE⁺-Fahrermodell wesentlich deutlicher ausgeprägt und entspricht eher dem Blickverhalten der Versuchspersonen.

Es lassen sich zwei Aspekte identifizieren, die ursächlich für diese Veränderung der Blickdauern sind. Einerseits steigt die durchschnittliche Abweichung von der Spurmitte mit steigender Streckenkrümmung an. Hierauf wird in Abschnitt 5.8.2.2 zum Fahrverhalten weiter eingegangen. Die höhere Abweichung von der Spurmitte führt zu längeren Stabilisierungsphasen und damit zu längeren Blicken. Dies ist der Effekt, der sich auch beim –AIE-Fahrermodell zeigte. Ein weiterer Grund liegt in der erhöhten Ereignisrate für die Lateralkontrolle. Da ein Großteil der Aufmerksamkeit bereits auf die Lateralkontrolle gerichtet ist, führt eine Erhöhung der Ereignisrate dazu, dass bei der Zielauswahl die Wahrscheinlichkeit steigt, dass die Lateralkontrolle erneut als nächstes Ziel ausgewählt wird, obwohl es bereits aktiv ist. Dadurch wird der Blick nicht auf eine andere Informationsquelle gerichtet, wodurch die durchschnittliche Blickdauer zur Straße weiter steigt.

Bei den Blicken zum NRBT-Display und zum Tachometer zeigt sich keine Trendübereinstimmung bei Veränderung der Streckenbedingung. Die Blickdauern des Fahrermodells bleiben annähernd konstant, da sich die durchschnittliche Dauer der Aufgabebearbeitung nicht ändert. Lediglich die durchschnittlichen Blickdauern zum NRBT-Display steigen beim Fahrermodell leicht an, da durch die reduzierte Blickfrequenz die Wahrscheinlichkeit ansteigt, dass wenn der Blick auf das NRBT-Display gerichtet wird, eine neue Ziffernfolge vorhanden ist. Dies erfordert eine Reaktion des Fahrermodells, die Zeit benötigt, wodurch die durchschnittliche Blickdauer zum NRBT-Display steigt. Im Gegensatz zum Fahrermodell sinken die Blickdauern der Versuchspersonen zum Tachometer bzw. NRBT-Display bei steigender Streckenkrümmung. Es scheint also, dass diese Aufgaben schneller bearbeitet werden, wenn Zeitdruck durch andere Aufgaben erzeugt wird. Einen entsprechenden Mechanismus, um diesen Effekt zu simulieren, besitzt CASCaS nicht. Die beobachteten Effekte bei den Blickdauern widersprechen zudem der von Moray (1986) und Just und Carpenter (1980) angeführten Annahme, dass die Blickdauer hauptsächlich durch die Schwierigkeit der Informationsaufnahme bestimmt wird. Die Informationen auf dem Tachometer und dem NRBT-Display werden jedoch immer auf die gleiche Weise dargestellt.

Bei der Manipulation der NRBT-Aufgabenrate lässt sich eine gute Trendübereinstimmung für die Blickdauern zum NRBT-Display finden (s. Abbildung 5.28, Mitte). Die Blickdauern steigen an, da durch die erhöhte Aufgabenrate die Wahrscheinlichkeit steigt, dass wenn der Blick auf das NRBT-Display gerichtet wird, eine neue Ziffernfolge vorhanden ist. Da dies eine Reaktion des Fahrermodells erfordert, sind die Blicke zum NRBT-Display bei hoher NRBT-Aufgabenrate im Durchschnitt länger. Auch die Blickdauer des Fahrermodells zur Straße steigt an. Ursache hier-

für ist der Anstieg der Blickdauer und -frequenz zum NRBT-Display. Dies führt zu häufigeren und längeren **Blickablenkungsdauern** von der Straße. Dies wiederum führt zu stärkeren lateralen Abweichungen von der Spurmitte (s. Abschnitt 5.8.2.2). Die höheren Abweichungen erfordern schließlich längere Stabilisierungsphasen und damit längere Blicke zur Straße. Die Versuchspersonen zeigen bei den Blickdauern zur Straße jedoch einen entgegengesetzten Trend. Auch hier scheint der Effekt aufzutreten, dass Aufgaben schneller bearbeitet oder früher unterbrochen werden, wenn Zeitdruck durch andere Aufgaben erzeugt wird. Dies wird von CASCaS oder dem AIE-Modell nicht berücksichtigt. Das Fahrermodell reproduziert diesen Effekt daher nicht.

Wie auch schon bei den PDTs und den Blickfrequenzen sind die Abweichungen zwischen Fahrermodell und Versuchspersonen bei der Manipulation der **Aufgabenpriorität** am größten. Besonders auffällig sind hier die unterschiedlichen Werte für die Blickdauern zur Straße. Die Versuchspersonen zeigten einen sehr großen Effekt bei Priorisierung der Lateralkontrolle im Vergleich zur Priorisierung der NRBT bzw. Longitudinalkontrolle. Der Effekt beim AIE⁺-Fahrermodell ist dagegen vergleichsweise klein. Die sehr kurzen Blickdauern zur Straße bei den Versuchspersonen bei Priorisierung der NRBT bzw. Longitudinalkontrolle deuten wieder auf den Effekt hin, dass Aufgaben scheinbar schneller bearbeitet oder früher unterbrochen werden, wenn Druck durch andere Aufgaben entsteht, d. h. wenn die Aufmerksamkeitsgewichte der anderen Aufgaben sehr hoch sind. Dies wird bei der Aufgabenbearbeitung durch CASCaS nicht berücksichtigt.

5.8.2.1.5 Timing der Blicke

Bisher wurde das Blickverhalten über längere Zeiträume charakterisiert anhand von aggregierten Werten wie PDTs und Blickfrequenzen. Das AIE-Modell adressiert jedoch auch speziell Charakteristika des Blickverhaltens innerhalb kurzer Zeiträume. Durch die **Ereignisfunktion** steigt die Erwartung von **Ereignisse** kontinuierlich seit dem letzten Ereignis an und fällt zurück auf 0, sobald ein neues Ereignis beobachtet wird. Die Erwartung eines kognitiven Agenten ändert sich daher stark zwischen zwei Ereignissen. Die Begründung hinter dieser Modellierung mittels der Ereignisfunktionen liegt darin, dass die Wahrscheinlichkeit, mit der ein kognitiver Agent auf eine Informationsquelle schaut, mit der Wahrscheinlichkeit steigen soll, dass dort neue und relevante Informationen vorhanden sind.

Wie diese Modellierung das Timing von Blickbewegungen beeinflusst, lässt sich sehr gut anhand der Nebenaufgabe verdeutlichen. Der Zeitpunkt, an dem die Fahrer auf eine neue Ziffernfolge reagieren, stellt ein Ereignis dar und lässt sich gut als Referenzpunkt verwenden, da er durch den Lenkradtastendruck einfach zu identifizieren ist. In Abbildung 5.29 ist die Blickverteilung zum NRBT-Display in der Zeit nach einem Tastendruck dargestellt. Hierzu wurden alle Tastendrucke in den Experimentaldaten des ersten Versuchsblocks identifiziert. Beginnend beim Tastendruck wurden Ausschnitte aus den Datenreihen mit einer Länge von jeweils 13 Sekunden extrahiert. Die Datenreihen in Abbildung 5.29(a) geben nun den Anteil der Datensamples an, bei denen der Blick der Versuchspersonen auf das NRBT-Display gerichtet ist. Dabei ist der Anteil über den zeitlichen Verlauf nach der Reaktion auf die letzte Ziffernfolge aufgetragen. Dies wurde einmal durchgeführt für die Daten aus den Versuchsbedingungen mit hoher NRBT-Aufgabenrate (grauer, durchgezogener Graph) und einmal bei niedriger Aufgabenrate (gestrichelter Graph).

Zum Zeitpunkt des Tastendrucks ist der Blickanteil zum NRBT-Display enorm hoch, da die Fahrer typischerweise auf die Lenkradtaste drücken, während sie auf

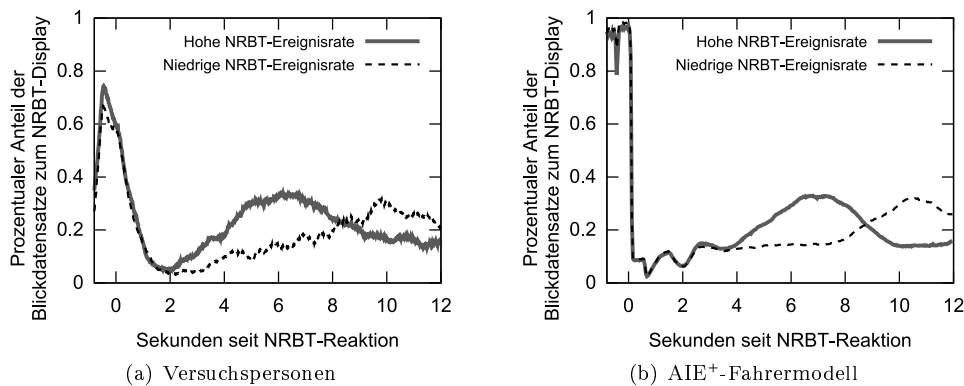


Abbildung 5.29 – Anteil der Datensamples mit Blick zum NRBT-Display nach der Reaktion auf eine neue NRBT-Ziffernfolge, separat aufgetragen für die Versuchsbedingungen mit niedriger Aufgabenrate (gestrichelter Graph) und hoher Aufgabenrate (grauer, durchgezogener Graph).

das NRBT-Display schauen. Danach sinkt die Blickverteilung zum Display beinahe gegen 0. Bei hoher Aufgabenrate steigt die Blickverteilung früher wieder an als bei niedriger Aufgabenrate, da die Fahrer früher neue Ziffernfolgen erwarten.

Der gleiche Effekt lässt sich aufgrund der Ereignisfunktionen auch beim AIE-Fahrermodell beobachten (Abbildung 5.29(b)). Die ungewöhnlichen Schwankungen der beiden Kurven in Abbildung 5.29(b) im Bereich von 0-3 s sind lediglich Artefakte, die durch die Blicke zum NRBT-Display und zum Tachometer entstehen. Da die Dauern dieser Blicke bis auf einen kleinen Rauschanteil immer gleich lang sind, entstehen diese regelmäßigen Muster.

Insbesondere der Kurvenverlauf für die niedrige NRBT-Ereignisrate zeigt gut den Einfluss der Wertparameter. Bis auf die Artefakte innerhalb der ersten drei Sekunden bleibt der Anteil der Blickdatensamples bis etwa 7.5 s nach dem Tastendruck gleich. Dieser Anteil kommt nur durch den Wertfaktor zustande. Der Erwartungsparameter für die NRBT ist innerhalb dieses Zeitraums 0, da keine Ereignisabstände in dieser Größenordnung auftreten und die Ereignisfunktion für den NRBT in diesem Bereich folglich 0 ist. Anschließend wächst die Ereignisfunktion und der Kurvenverlauf in der Abbildung steigt um bis zu 19 Prozentpunkte. Die Ereignisfunktionen sind jedoch nicht alleine verantwortlich für diesen Effekt. Auch die Dauer der Aufgabenbearbeitung spielt eine Rolle. Wenn eine neue Ziffernfolge vom Fahrermodell entdeckt wird, dann benötigt das Drücken der Lenkradtaste und das Vorlesen der Ziffern mehr Zeit als ein einfacher Blick zum NRBT-Display, wenn keine neue Ziffernfolge angezeigt wird. Dadurch steigt der Blickanteil zum NRBT-Display auch deshalb in dem Zeitraum an, in dem neuen Ziffernfolgen erscheinen, weil in diesem Zeitraum die Blickdauern zum NRBT-Display länger sind. Welchen Anteil die Ereignisfunktionen an diesem Effekt haben und welcher Anteil auf die erhöhten Blickdauern zurückzuführen ist, wird in Abschnitt 5.8.5 genauer untersucht.

5.8.2.2 Qualität der Aufgabenbearbeitung

Bisher wurde das Blickverhalten des AIE⁺-Fahrermodells mit den Experimentaldaten verglichen. Die dabei beobachteten Effekte spiegeln sich jedoch auch in der Bearbeitung der drei Aufgaben wider. Ziel des AIE-Modells ist zwar die Simulati-

on der Aufmerksamkeitsverteilung, allerdings sind Aufgabenbearbeitung und Aufmerksamkeitsverteilung eng miteinander verknüpft und sollten auch in Kombination untersucht werden (Land und Tatler, 2009). Das ist im Kontext des AIE-Modells umso interessanter. Es schafft eine direkte Verbindung zwischen Aufgabenmodell und Aufmerksamkeitsverteilung, da die Ereignisse, über die die Erwartungsparameter definiert sind, aus den Produktionsregeln des Aufgabenmodells abgeleitet werden. In Abschnitt 5.5.2 wurde die Qualität der Aufgabenbearbeitung durch die Versuchspersonen jeweils anhand eines Gütemaßes bewertet. Dies war für die Lateralkontrolle die durchschnittliche Abweichung von der durchschnittlichen Spurposition. Für die Longitudinalkontrolle war es die Durchschnittsgeschwindigkeit und die durchschnittliche Abweichung von der Sollgeschwindigkeit (100 km/h). Die Güte der NRBT-Bearbeitung wurde anhand der Reaktionszeiten und Fehlerhäufigkeiten bewertet.

Im Folgenden wird die Qualität der Aufgabenbearbeitung des AIE⁺-Fahrermodells dargestellt und mit den Daten der Versuchspersonen verglichen. Eine Diskussion der hier dargestellten Ergebnisse findet sich auch in Wortelen et al. (2013b).

In Abbildung 5.30 sind die Effekte, die die Manipulationen der unabhängigen Variablen auf die Qualität der Aufgabenbearbeitung haben, für jede Aufgabe und jede unabhängige Variable dargestellt. Die grauen, durchgezogenen Linien beschreiben das Verhalten der Versuchspersonen und die schwarzen, gestrichelten Linien das des AIE⁺-Fahrermodells. Kenngrößen der Modellanpassungsgüte über alle Versuchsbedingungen sind für die gewählten Gütemaße in Tabelle 5.10 aufgelistet. Viele Eigenschaften, die sich im Verhalten der Versuchspersonen zeigen, werden vom Fahrermodell wiedergegeben. Es zeigen sich jedoch auch einige Unterschiede.

Bei der Manipulation der Streckenschwierigkeit gibt das Fahrermodell den allgemeinen Trend wieder, dass die Qualität der Aufgabenbearbeitung bei allen drei Aufgaben mit steigender Streckenschwierigkeit nachlässt. Die Beobachtung, dass die Qualität stärker zwischen der mittleren und schweren Streckenschwierigkeit zurückgeht als zwischen der leichten und mittleren Schwierigkeit, lässt sich sowohl bei den Versuchspersonen, als auch beim Fahrermodell machen. Allerdings ist dieser Effekt bei den Reaktionszeiten des Fahrermodells deutlich geringer als bei den Versuchspersonen.

Die starken durchschnittlichen Abweichungen von der mittleren Spurposition, die bei der schweren Streckenbedingung zu beobachten sind, sind auch die Ursache für die hohen Blickdauern zur Straße und den allgemein niedrigen Blickfrequenzen in dieser Versuchsbedingung, da durch die laterale Abweichung eine hohe Ereignisrate auftritt und viel Zeit in die Fahrzeugstabilisierung investiert werden muss.

Bei der Durchschnittsgeschwindigkeit und der Abweichung von der Sollgeschwindigkeit sticht die Diskrepanz zwischen den absoluten Werten direkt ins Auge. In Tabelle 5.10 sind Kenngrößen der Modellanpassungsgüte für die verschiedenen Aspekte der Aufgabenbearbeitung aufgelistet. Bei der Abweichung von der Sollgeschwindigkeit beträgt die RMSD über alle Versuchsbedingungen für das AIE⁺-Fahrermodell 0.876 km/h und bei der Durchschnittsgeschwindigkeit 1.336 km/h. Um die Abweichungen bei den verschiedenen Aspekten vergleichen zu können, wurde für jeden Datenpunkt eine Standardisierung anhand der Versuchspersonenvarianz durchgeführt (Z-Transformation). In Tabelle 5.10 sind die durchschnittlichen Beträge der z-Werte ($|z|$) für jeden untersuchten Aspekt aufgetragen. Die Tabelle offenbart, dass die absoluten Abweichungen bei der Longitudinalkontrolle mit 0.637 bzw. 0.879 Standardabweichungen im Vergleich zu den Abweichungen bei den anderen beiden Gütemaßen tatsächlich deutlich größer ist.

Die Durchschnittsgeschwindigkeit des Fahrermodells liegt immer unterhalb der Soll-

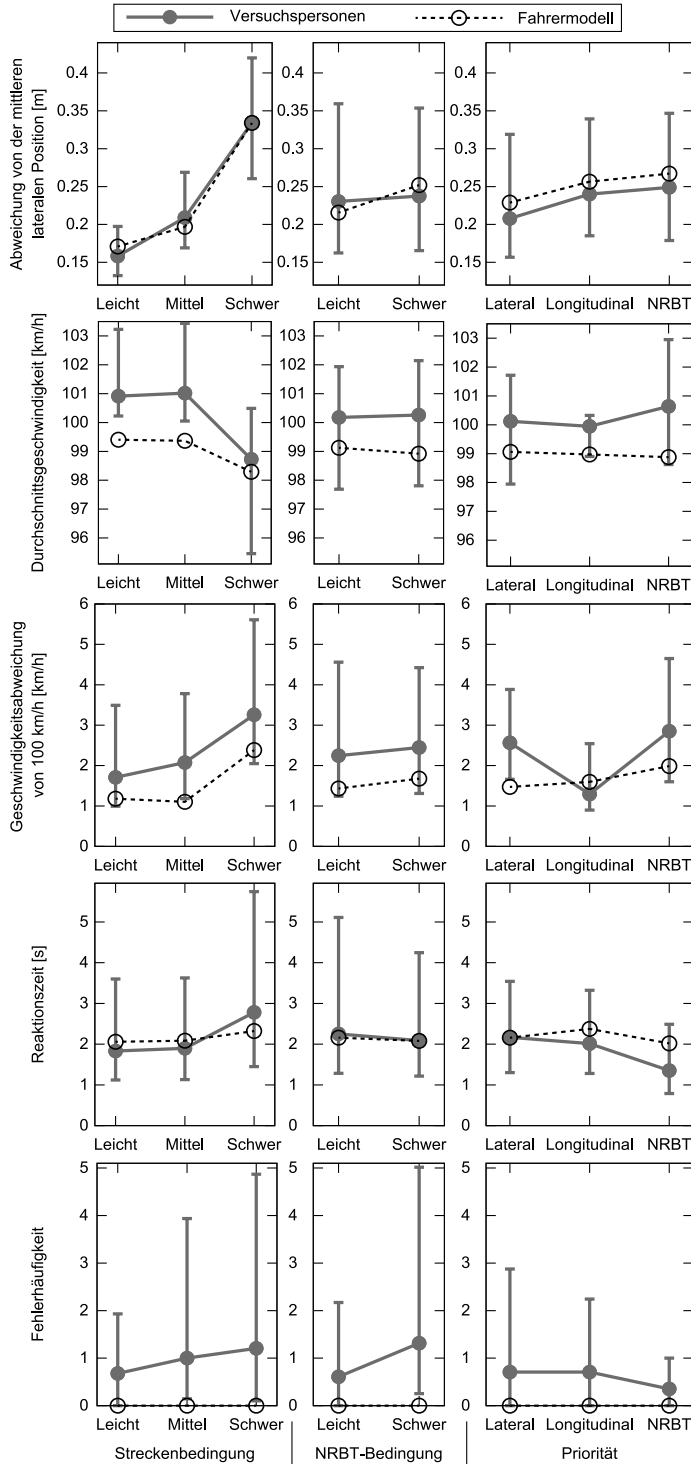


Abbildung 5.30 – Qualität der Aufgabenbearbeitung bei Manipulation der unabhängigen Variablen. Die Daten der Versuchspersonen sind als durchgezogene Linien dargestellt und die des AIE⁺-Fahrermodells als gestrichelte Linien.

	R^2	RMSD	$ z $	Regressionsgerade
Abweichung von der mittleren Spurposition	0.935	0.020 m	0.287	$-0.009 + 1.070 \cdot x$
Abweichung von 100 km/h	0.419	0.876 km/h	0.637	$0.284 + 0.582 \cdot x$
Durchschnittsgeschwindigkeit	0.707	1.336 km/h	0.879	$53.4 + 0.455 \cdot x$
NRBT Reaktionszeit	0.127	444 ms	0.368	$1927 + 0.112 \cdot x$

Tabelle 5.10 – Kenngrößen der Modellanpassungsgüte bezüglich der gewählten Gütemaße für die drei Aufgaben des AIE⁺-Fahrermodells.

geschwindigkeit und ist nahezu konstant. Lediglich bei der schweren Streckenbedingung sinkt sie noch weiter. Die Durchschnittsgeschwindigkeit ist geringer als die Sollgeschwindigkeit, da durch Lenkbewegungen die Geschwindigkeit des Fahrzeugs reduziert wird. In der schwierigen Streckenbedingung ist dieser Effekt am größten. Die Ursache liegt also nicht im AIE-Modell. Bei den weiteren Simulationen wird die Durchschnittsgeschwindigkeit daher nicht weiter betrachtet.

Da die Abweichungen von der Sollgeschwindigkeit des AIE⁺-Fahrermodells in allen Versuchsbedingungen geringer sind als bei den Versuchspersonen, liegt die Vermutung nahe, dass die Parameter für die Longitudinalkontrolle nicht optimal gewählt sind. Dafür spricht auch, dass bei der Bewertungsfunktion für die Parameterschätzung (s. Abschnitt 5.7) die Stabilität der Lateralkontrolle dreimal so stark gewichtet wurde, wie die Stabilität der Longitudinalkontrolle. Da das Schätzverfahren aufgrund des großen Zeitaufwands irgendwann abgebrochen werden musste, ist es durchaus wahrscheinlich, dass sich für die Longitudinalkontrolle noch bessere Parameter finden lassen.

Für die Aufgabenbearbeitung der Nebenaufgabe wird die Fehlerhäufigkeit nicht weiter betrachtet, da das Fahrermodell keine Mechanismen beinhaltet, die zu einer fehlerhaften oder unvollständigen Wiedergabe der Ziffernfolge führen. Die absoluten Abweichungen bei den Reaktionszeiten sind mit einem durchschnittlichen $|z|$ -Wert von 0.368 Standardabweichungen zwar nur halb so groß, wie bei den Abweichungen von der Zielgeschwindigkeit, dafür wird jedoch die Variabilität in den Reaktionszeiten nur sehr schlecht vom AIE⁺-Fahrermodell erklärt ($R^2 = 0.127$). Lediglich für die Lateralkontrolle ist die Modellanpassung sowohl im Trend ($R^2 = 0.935$), als auch in den absoluten Abweichungen ($z = 0.287$) sehr gut.

Die Manipulation der NRBT-Aufgabenrate zeigt einen Effekt bei der Abweichung von der mittleren Spurposition des Fahrermodells. Bei erhöhter NRBT-Aufgabenrate verringert sich die Qualität des Spurhaltens. Dieser Effekt wird jedoch nicht von den Versuchsdaten unterstützt. Die Versuchspersonen scheinen daher im Gegensatz zum Fahrermodell gut in der Lage zu sein, die erhöhte Anforderung der Nebenaufgabe zu kompensieren.

Bei der Manipulation der **Aufgabenpriorität** ist die Modellanpassung je nach Gütemaß sehr unterschiedlich. Bei der Abweichung von der mittleren Spurposition zeigt sich eine gute Anpassung, die den Trend der Versuchspersonen wiedergibt und nur eine geringe absolute Abweichung aufweist. Anders sieht es bei den NRBT-Reaktionszeiten aus. Die Reaktionszeiten des Fahrermodells reduzieren sich nicht nur bei der Priorisierung der NRBT, sondern auch bei Priorisierung der Lateralkontrolle. Die Nebenaufgabe scheint beim Fahrermodell daher, anders als bei den

Versuchspersonen, von einer verbesserten Lateralkontrolle zu profitieren.


Als Ursache wird hier die starre Bearbeitungsweise der Aufgaben in CASCaS vermutet. Die Ereignisraten und Aufgabenprioritäten wirken sich nur auf die Auswahl der Aufgabenziele aus. Auf die Art und Weise, mit der die jeweiligen Aufgaben bearbeitet werden, haben sie keinen direkten Einfluss. Das bedeutet, dass eine Aufgabe immer gleich schnell und gleich sorgfältig ausgeführt wird. Dies führte bereits bei der Betrachtung der Blickdauern zu Diskrepanzen zwischen Fahrermodell und Versuchspersonen (s. Abschnitt 5.8.2.1.4). Die Versuchspersonen reduzierten die Blickdauer zu einer Informationsquelle, wenn durch eine hohe Ereignisrate oder Priorität das Aufmerksamkeitsgewicht einer anderen Informationsquelle sehr hoch war. Das bedeutet, sie wurden entweder effizienter bei der Bearbeitung der Aufgaben, oder waren weniger sorgfältig. Folgt man dieser Argumentation, könnte der Effekt auch hier eine Rolle spielen. Eine hohe Priorität der Lateralkontrolle führt dazu, dass das Ziel häufig ausgewählt wird. Das wirkt sich positiv auf die Spurführung aus (s. Abbildung 5.30, oben rechts). Wenn das Stabilitätskriterium der Lateralkontrolle (s. Prozedurabschnitt 5.2) dennoch verletzt wird, stabilisiert das Fahrermodell das Fahrzeug (Ziel: `stabilize_car`). Durch die gute Spurführung sind die Abweichungen meist gering und die Stabilisierung ist schnell beendet. Dadurch wird schneller erneut eine Zielauswahl durchgeführt. Somit treten Zielauswahlen häufiger auf und der NRBT wird trotz des geringeren Auswahlgewichts häufiger ausgewählt. Das schließlich reduziert die Reaktionszeiten. Der gleiche Effekt lässt sich mit gleicher Begründung aber in schwächerer Form auch bei der Longitudinalkontrolle beobachten. Die geringsten Abweichungen von der Zielgeschwindigkeit treten nicht nur bei Priorisierung der Longitudinalkontrolle auf, sondern auch bei Priorisierung der Lateralkontrolle. Dies würde unterbunden werden, wenn mit steigender Priorität auch die Sorgfalt der Aufgabenbearbeitung steigt. Im Fall der Lateralkontrolle könnte es bedeuten, dass bei hoher Priorität der Lateralkontrolle ein strengeres Stabilitätskriterium vom Fahrermodell gewählt wird, et vice versa. Dies würde Häufigkeit und Dauer der Stabilisierungsphasen erhöhen und damit voraussichtlich auch die Reaktionszeiten erhöhen. Diese Ideen gehen jedoch über das AIE-Modell hinaus, da sie nicht die Auswahl der Aufgabenziele, sondern die Aufgabenbearbeitung betreffen. Sie wurden daher nicht weiter verfolgt.

5.8.2.3 Lernphase

Wie dies bereits im vorherigen Kapitel für Senders' Aufgabe geschehen ist, so wird hier nun die Lernphase des AIE⁺-Fahrermodells näher betrachtet. Dabei soll vor allem die Frage geklärt werden, ob sich auch in dieser etwas komplexeren Simulation wieder die erwartete Lerngeschwindigkeit der Form $a \cdot t^{-b}$ zeigt.

Hierzu wurde das AIE⁺-Fahrermodell in der Versuchsbedingung mit mittlerer Streckenschwierigkeit, niedriger NRBT-Aufgabenrate und bei gleicher **Aufgabenpriorisierung** 12-mal für jeweils 105 Minuten simuliert. Alle fünf Minuten wurden die Ereignisfunktionen für alle Ziele aufgezeichnet. Um die Unterschiedlichkeit zwischen zwei Ereignisfunktionen zu bestimmen, wurde erneut das Differenzmaß V_K aus Kuipers Test verwendet.

In Abbildung 5.31(a) sind für die drei Ziele `lateral_control`, `free_ride` und `number_read_back_task` die durchschnittlichen V_K -Werte zu sehen, die sich aus dem paarweisen Vergleich der Ereignisfunktionen aus den 12 Simulationen ergeben. Sie sind als gestrichelte Linie über die Simulationszeit aufgetragen. Es lässt sich gut erkennen, dass ein Großteil der Unterschiede nach etwa 20-40 Minuten abgebaut ist. Die Art des Kurvenverlaufs ähnelt sich bei jeder der drei Kurven und scheint



(a) Die gestrichelten Linien zeigen jeweils die berechneten V_K -Werte und die durchgezogenen Linien angepasste Funktionen der Form $f(t) = a \cdot t^{-b}$.

(b) Annähernd linear und parallel verlaufende V_K -Werte in einem logarithmischen Koordinatensystem deuten auf Funktionen der Form $f(t) = a \cdot t^{-b}$ hin mit jeweils identischem Exponenten b .

Abbildung 5.31 – Verlauf der Lernphase für die Ereignisfunktionen der drei Aufgaben. Aufgetragen ist das durchschnittliche V_K -Maß zur Bestimmung der Ähnlichkeit der Ereignisfunktionen aus den 12 Simulationsläufen.

dem erwarteten Verlauf von $a \cdot t^{-b}$ zu folgen. Die Darstellung der Daten in einem zweifach logarithmisch skalierten Koordinatensystem (Abbildung 5.31(b)) führt wie schon bei Senders Aufgabe zu annähernd linearen und parallelen Kurvenverläufen und bestärkt daher den vermuteten Kurvenverlauf mit identischem Exponenten b für alle Ziele.

Die Parameter a und b wurden nun für alle drei Aufgaben über die Methode der kleinsten Quadrate geschätzt unter der Restriktion, dass der Parameter b für alle Funktionen identisch ist. Dies führte zu den Parameterschätzungen

$$\begin{aligned} a_{lateral_control} &= 0.230, & a_{free_ride} &= 0.053, \\ a_{NRBT} &= 0.156 = 0.156, & b &= 0.418, \end{aligned}$$

Der lineare Verlauf der Lernkurven in der logarithmischen Darstellung ist nicht ganz so deutlich zu erkennen, wie bei der Untersuchung des Lernverlaufs bei Senders Aufgabe. Ein Grund hierfür liegt höchstwahrscheinlich in der Anzahl der V_K -Werte. Da die Fahrsimulationssoftware nur Echtzeitsimulationen erlaubt, wurden aufgrund des hohen zeitlichen Aufwands lediglich 12 Simulationen durchgeführt, so dass jeder Datenpunkt über $\sum_{i=1}^{12-1} i = 66$ V_K -Werte gemittelt wurde. Bei Senders Aufgabe waren dies 190.

Die Anpassung an die gemessene Lerngeschwindigkeit ist in Abbildung 5.31(a) grafisch zu sehen. Dort sind die gemessenen Lerngeschwindigkeiten als gestrichelte Linie und die angepassten Kurven als durchgezogene Linien zu sehen.

Was dies im Endeffekt für die Ereignisfunktionen bedeutet ist in Abbildung 5.32 dargestellt. Zu sehen sind die Ereignisfunktionen nach 105 Minuten Simulation gemittelt über alle 12 Simulationsläufe. Der eingefärbte Bereich um die Funktionen herum beschreibt die Standardabweichung. Es ist zu sehen, dass die Ereignisfunktionen für die Lateral- und Longitudinalkontrolle über einen längeren Bereich anwachsen, während die Funktion für den NRBT nur in einem kleinem Bereich steigt. Dies führt auch zu dem in Abbildung 5.29(b) dargestellten Effekt auf das Timing




Abbildung 5.32 – Punktwise gemittelte Ereignisfunktionen von 12 Simulationsläufen nach 105 Minuten Simulation bei mittlerem Kurvenradius und leichter NRBT-Schwierigkeit. Der Bereich um die gemittelten Funktionen ist die Standardabweichung vom Mittelwert.

der Blicke zum NRBT-Display. Dieser Aspekt wird im nächsten Abschnitt weiter diskutiert.

5.8.3 AIE*-Fahrermodell

Wie auch der Agent für Senders Aufgabe wurde das Fahrermodell in verschiedenen Konfigurationen simuliert. Für die Variante mit multiplikativer Verknüpfung der Erwartungs- und Wertparameter (AIE*-Fahrermodell) wurden die gleichen Analysen vorgenommen, wie für das AIE⁺-Fahrermodell. Es wurden auch mit dieser Variante für alle 12 Versuchsbedingungen je 5 Simulation mit einer Dauer von je 125 Minuten durchgeführt, wobei wiederum die ersten 50 Minuten jeweils zum Trainieren der Ereignisfunktion verwendet wurden und die verbleibenden 75 Minuten für die Datenanalyse.

Viele Beobachtungen und Überlegungen, die im vorherigen Abschnitt für das AIE⁺-Fahrermodell gemacht wurden, treffen auch auf die AIE*-Variante zu. Daher werden hier nicht alle Analysen im Detail gezeigt, sondern es wird nur auf die Unterschiede zum AIE⁺-Fahrermodell eingegangen. Ebenso wie für das AIE⁺-Fahrermodell finden sich detaillierte Analyseergebnisse zum AIE*-Fahrermodell tabellarisch in Anhang C.

Einige Unterschiede im Modellverhalten zwischen der additiven und der multiplikativen Variante des AIE-Modells wurden bereits in (Wortelen et al., 2013c) präsentiert.

5.8.3.1 Modellanpassungsgüte

Die Modellanpassungsgüte des AIE*-Fahrermodells ist in vielen Aspekten etwas schlechter als die des AIE⁺-Fahrermodells, vor allem bezogen auf das Blickverhalten. In Tabelle 5.11 sind die Kennwerte für das Blickverhalten und die Güte der Aufgabenbearbeitung aufgelistet. Die Abweichungen der absoluten Werte im Vergleich zum AIE⁺-Fahrermodell sind deutlich höher. Lediglich bei der Abweichung zur Sollgeschwindigkeit hat sich eine Verbesserung eingestellt, die sich sowohl in

	R^2	RMSD	$ z $	Regressionsgerade
PDTs	0.960	0.113	1.628	$-0.119 + 1.315 \cdot x$
Blickfrequenzen	0.731	0.215 Hz	1.741	$-0.003 + 0.505 \cdot x$
Blickdauern	0.832	0.696 s	2.028	$-833 + 2.223 \cdot x$
Geschwindigkeitsabweichung von 100 km/h	0.680	0.71 km/h	0.427	$0.602 + 0.492 \cdot x$
NRBT Reaktionszeit	0.181	448 ms	0.350	$1229 + 0.348 \cdot x$
Abweichung von der middle- ren Spurposition	0.922	0.080 m	1.664	$-0.139 + 1.276 \cdot x$

Tabelle 5.11 – Kennwerte der Modellanpassungsgüte für das AIE*-Fahrermodell.

den absoluten Abweichungen (AIE⁺: 0.876 km/h, AIE*: 0.71 km/h), als auch der Korrelation zwischen Fahrermodell und Versuchspersonen zeigt (AIE⁺: $R^2=0.419$, AIE*: $R^2=0.68$).

Die Korrelationskoeffizienten haben sich ansonsten nur bei den Blickfrequenzen stärker geändert. Hier ist die Korrelation deutlich schlechter als beim AIE⁺-Fahrermodell (AIE⁺: $R^2=0.878$, AIE*: $R^2=0.731$).

5.8.3.2 Blickverhalten

Das Blickverhalten des AIE*-Fahrermodells zeigt viele Gemeinsamkeiten mit der AIE⁺-Variante. Allerdings zeigen sich auch einige Unterschiede, die in der Art ähnlich zu den Unterschieden sind, die sich bei Senders Aufgabe zwischen dem AIE⁺ und dem AIE*-Agenten gezeigt haben. Die Anpassungsgüte an das Blickverhalten der Versuchspersonen ist für die meisten betrachteten Aspekte schlechter als beim AIE⁺-Fahrermodell. Die Unterschiede zwischen den Modellalternativen werden hier nun näher betrachtet, um zu diskutieren, welche Rückschlüsse sich daraus auf die Wahl zwischen additiver und multiplikativer Verknüpfung der Erwartungs- und Wertparameter ziehen lassen.

Die Korrelation der PDTs ist mit $R^2=0.96$ ähnlich hoch wie beim AIE⁺-Fahrermodell ($R^2=0.958$). Allerdings sind alle anderen Werte größtenteils deutlich schlechter. Insbesondere sind die absoluten Abweichungen gemessen am RMSD bedeutend größer. Die Ursachen werden deutlich, wenn man das Blickverhalten bei Manipulation der Streckenbedingung betrachtet. In Abbildung 5.33 sind die Effekte auf die PDTs, Blickfrequenzen und Blickdauern abgebildet. Das AIE*-Fahrermodell gibt die generellen Tendenzen bei den PDTs und den Blickfrequenzen wieder. Wie auch beim AIE⁺-Fahrermodell zeigt die Manipulation der Streckenschwierigkeit jedoch keinen Einfluss auf die Blickdauern zum Tachometer, obwohl dies bei den Versuchspersonen der Fall war (rechtes Diagramm). Auch der Einfluss auf die Blickdauern zum NRBT-Display ist sehr gering und in der Tendenz entgegengesetzt zu den empirischen Werten. Ursache ist auch hier wieder, dass CASCaS kein Modell beinhaltet, das die Blickdauern den Erwartungswerten oder der [Aufgabenpriorität](#) anpasst. Sehr auffällig in allen drei Diagrammen sind jedoch die absoluten Abweichungen zwischen den Werten des Fahrermodells und den Werten der Versuchspersonen. Die Blickfrequenzen sind zu allen Informationsquellen geringer als bei den Versuchspersonen. Das ist auch die Ursache für die bessere Modellanpassung bezüglich der

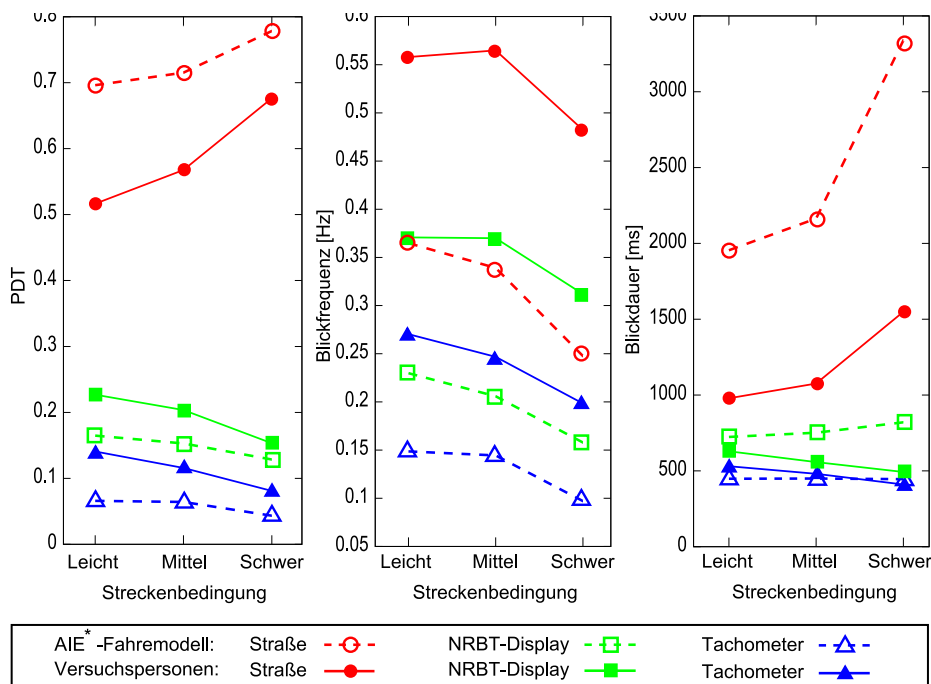


Abbildung 5.33 – Blickverhalten des AIE*-Fahrermodells bei Manipulation der Streckenbedingung.

Longitudinalkontrolle. Diese ist beim AIE⁺-Fahrermodell schlechter, da das AIE⁺-Fahrermodell die Geschwindigkeit besser kontrolliert als die Versuchspersonen, was ein Zeichen für eine unzureichende Modellierung der Longitudinalkontrolle ist. Das AIE⁺-Fahrermodell kompensiert diesen Effekt durch die geringere Blickfrequenz zur Geschwindigkeitsanzeige etwas. Dies führt zu einer schlechteren Qualität der Longitudinalkontrolle als beim AIE⁺-Fahrermodell und entspricht daher eher den experimentellen Daten. Somit sollte die bessere Anpassungsgüte des AIE⁺-Fahrermodells für die Longitudinalkontrolle nicht als ein Indikator angesehen werden, der für die multiplikative Variante des AIE-Modells spricht, da die schlechtere Anpassungsgüte beim Blickverhalten der eigentlich Grund für die bessere Anpassungsgüte bei der Longitudinalkontrolle ist.

Die PDTs zur Straße werden systematisch überschätzt, und die zum NRBT-Display und Tachometer unterschätzt. Betrachtet man die Korrelationsgerade für die PDTs ($PDT_{\text{Fahrermodell}} = -0.119 + 1.315 \cdot PDT_{\text{Versuchspersonen}}$), so zeichnet sich ein ähnliches Bild wie beim AIE⁺-Agenten für Senders Aufgabe. Hohe PDTs werden überschätzt, während niedrige PDTs unterschätzt werden. Der Grund hierfür wird offensichtlich, wenn man die Blickdauern zur Straße betrachtet, die deutlich über den empirischen Werten liegen. Das lässt darauf schließen, dass die Auswahlwahrscheinlichkeit der Lateralkontrolle deutlicher höher ist als beim AIE⁺-Fahrermodell, da wie bereits erwähnt eine Erhöhung der Auswahlwahrscheinlichkeit von Zielen, die schon ein hohes **Aufmerksamkeitsgewicht** besitzen, zu höheren Blickdauern zu der jeweiligen Informationsquelle und insgesamt zu einer Verringerung der Blickfrequenzen führt. Auch häufigere oder längere Stabilisierungsphasen können die Blickdauer zur Straße erhöhen. Dem widerspricht jedoch die deutlich niedrigere Abweichung von der mittleren Spurposition, die sich beim AIE⁺-Fahrermodell zeigt. Die mittlere Ab-




Abbildung 5.34 – Anteil der Datensamples des AIE⁺-Fahrermodells nach der Reaktion auf eine neue NRBT-Ziffernfolge, bei denen der Blick auf das NRBT-Display gerichtet ist. Die Werte sind separat aufgetragen für die Versuchsbedingungen mit niedriger Aufgabenrate (grün) und hoher Aufgabenrate (rot).

weichung von der mittleren Spurposition ist um durchschnittlich 0.095 m kleiner als die der Versuchspersonen und immerhin noch um 0.064 m kleiner als die des AIE⁺-Fahrermodells.

Die Ursache für die erhöhte Auswahlwahrscheinlichkeit der Lateralkontrolle wird deutlich, wenn man die Verläufe der Ereignisfunktion für die Lateralkontrolle und die NRBT vergleicht. Die Ereignisfunktionen sind in Abbildung 5.32 für das AIE⁺-Fahrermodell zu sehen. Die Kurvenverläufe für die AIE⁺-Variante sind in der Art jedoch ähnlich. Die Ereignisfunktionen der Lateralkontrolle und des NRBT steigen am stärksten und ziehen auch die meiste Aufmerksamkeit auf die jeweiligen Aufgaben. Betrachtet man die Kurve für die NRBT-Aufgabe, so sieht man, dass diese in den ersten Sekunden nach einem Ereignis 0 beträgt, da in dieser Zeitspanne keine neuen Ereignisse wahrgenommen wurden. Daher ist auch der Erwartungsparameter 0. Bei der multiplikativen Variante des AIE-Modells hat dies zur Folge, dass auch das Aufmerksamkeitsgewicht 0 ist, da dieses sich aus der Multiplikation von Erwartungs- und Wertparametern ergibt. In diesen Zeitspannen wird die Aufmerksamkeit also zwischen der Lateralkontrolle und der Longitudinalkontrolle aufgeteilt. Da die Ereignisrate für die Lateralkontrolle deutlich höher ist, wird diese häufig hintereinander ausgewählt. Das erzeugt die hohen Blickdauern zur Straße. Sehr deutlich wird der beschriebene Effekt, wenn man sich die Blickverteilung zum NRBT-Display nach einem neuen NRBT-Ereignis anschaut. Dies ist in Abbildung 5.34 dargestellt. Der Unterschied zum AIE⁺-Fahrermodell und auch zu den Versuchspersonen (vgl. Abbildung 5.29) ist gut zu erkennen. Das Fahrermodell richtet den Blick erst wieder auf das NRBT-Display, wenn auch tatsächlich neue Ziffernfolgen erschienen sein können. Es zeigt somit bezüglich des Aufgabenziels ein optimales Blickverhalten, da unnötige Blicke zum NRBT-Display vermieden werden. Dieser Aspekt der Optimalität wird auch in der ursprünglichen Argumentation für die multiplikative Variante des SEEV-Modells verwendet (Wickens et al., 2001), die auf Smallwoods (1967) zweiter Annahme aufbaut, dass der menschliche Bediener sich optimal verhält bezüglich seiner Aufgabe und seines Wissens über den aktuellen Stand und die Eigenschaften seiner Umgebung. Da weder die Versuchspersonen, noch das AIE⁺-Fahrermodell das hier dargestellte optimale Verhalten

zeigen, scheint diese Beobachtung gegen eine rein multiplikative Verknüpfung der Erwartungs- und Wertparametern zu sprechen.

Insgesamt zeigte das AIE*-Fahrermodell eine gute Modellanpassungsgüte an die experimentellen Daten, jedoch ist diese etwas schlechter als beim AIE⁺-Fahrermodell. Dies gilt insbesondere für die absoluten Abweichungen gemessen über die RMSD bei den Maßen zum Blickverhalten.

5.8.4 SE⁺-Fahrermodell

In Kapitel 4 wurden verschiedene Varianten des AIE-Modells für Senders Aufgabe evaluiert. Dazu zählten auch Varianten, die statische Erwartungsparameter (SE) anstelle der Ereignisfunktion verwenden. Dabei lieferten der SE⁺- und der SE*-Agent beinahe identische Ergebnisse wie der AIE⁺- beziehungsweise AIE*-Agent. Es stellt sich daher die Frage, ob die Verwendung der Ereignisfunktionen überhaupt notwendig ist, um eine sinnvolle Simulation der Aufmerksamkeitsverteilung zu erzielen. Estes (2002) bezeichnet ein Modell als adäquat, wenn es einerseits hinreichend ist, um die gewünschten Vorhersagen zu machen und andererseits auch notwendig. Ein Modell ist hinreichend für eine Situation, wenn es die empirischen Daten vorhersagen kann. Notwendig ist es, wenn das Entfernen einer beliebigen Modellannahme dazu führt, dass sich die empirischen Daten nicht mehr vorhersagen lassen. Für Senders Aufgabe ist sowohl der SE⁺- als auch der AIE⁺-Agent hinreichend, um die empirischen Daten aus Versuch 2 und 3 vorherzusagen. Jedoch ist der AIE⁺-Agent nicht notwendig, da sich die Daten auch ohne Ereignisfunktionen allein auf Basis der durchschnittlichen Ereignisraten mit gleicher Qualität vorhersagen lassen.

In diesem Abschnitt werden nun die Ergebnisse eines Fahrermodells präsentiert, die bei Verwendung von statischen Erwartungsparametern und additiver Kombination der Erwartungs- und Wertfaktoren erzielt wurden. Analog zu den Agenten für Senders Aufgabe, wird dieses Fahrermodell als SE⁺-Fahrermodell bezeichnet. Die Ergebnisse werden mit den Ergebnissen des AIE⁺-Fahrermodells verglichen und es wird diskutiert, für welche Vorhersagen das SE⁺-Modell hinreichend und das AIE⁺-Modell notwendig ist.

Für das SE⁺-Fahrermodell ist keine Trainingsphase notwendig, da keine Lerneffekte auftreten. Daher wurden alle Simulationsdaten für die Analyse verwendet. Das SE⁺-Fahrermodell wurde in jeder der zwölf Versuchsbedingungen für 375-Minuten simuliert. Dies entspricht der Simulationszeit, für die Daten des AIE⁺-Fahrermodells ausgewertet wurden.

Bei Senders Aufgabe sind die Raten bekannt, mit denen die einzelnen Signale der Anzeigeelemente den Alarmbereich betreten. Diese Raten wurden für die Erwartungsparameter des SE⁺-Agenten verwendet.

Für das Fahrermodell sind die Ereignisraten für die drei Aufgaben jedoch nicht bekannt, da alle Ereignisraten vom Verhalten des Fahrermodells abhängen. Es werden daher die Erwartungsfaktoren aus Tabelle 5.2 (S. 124) genutzt, die für die Vorhersagen des SEEV-Modells verwendet wurden und über den [Lowest-Ordinal-Algorithmus](#) bestimmt wurden.

5.8.4.1 Modellanpassungsgüte

Bei den meisten hier untersuchten Aspekten ist die Modellanpassungsgüte des SE⁺-Fahrermodells schlechter als die des AIE⁺-Fahrermodells. In Tabelle 5.12 sind die Kennwerte der Modellanpassungsgüte für die wichtigsten Maße des Blickverhaltens

	R^2	RMSD	$ z $	Regressionsgerade
PDTs	0.954	0.060	0.999	$0.066 + 0.840 \cdot x$
Blickfrequenzen	0.702	0.104 Hz	0.726	$0.196 + 0.588 \cdot x$
Blickdauern	0.776	0.686 s	1.752	$0.198 + 1.071 \cdot x$
Geschwindigkeitsabweichung von 100 km/h	0.358	0.710 km/h	0.454	$0.488 + 0.698 \cdot x$
NRBT Reaktionszeit	0.140	596 ms	0.537	$2203 + 0.113 \cdot x$
Abweichung von der mittleren Spurposition	0.203	0.165 m	3.534	$0.320 + 0.294 \cdot x$

Tabelle 5.12 – Kennwerte der Modellanpassungsgüte für das SE⁺-Fahrermodell.

und der Güte der Aufgabenbearbeitung aufgelistet. Insbesondere die Abweichung von der mittleren Spurposition unterscheidet sich mit einem durchschnittlichen z-Wert von 3.5 Standardabweichungen deutlich vom Verhalten der Versuchspersonen. Das Fahrverhalten ist annähernd so schlecht, wie das des \neg AIE-Fahrermodells. Auch die Auswirkungen auf die anderen Aspekte des Modellverhaltens sind ähnlich wie beim \neg AIE-Fahrermodell. Durch die schlechte Lateralkontrolle sind die Stabilisierungsphasen der Lateralkontrolle sehr lang, so dass auch die durchschnittliche Blickdauer zur Straße meist deutlich höher ist als bei den Versuchspersonen. Dies führt wiederum zu einer niedrigeren **Gesamtblickfrequenz** und höheren NRBT-Reaktionszeiten.

5.8.4.2 Transitionswahrscheinlichkeiten

Die Ursache für die schlechte Lateralkontrolle wird deutlich, wenn man die Transitionswahrscheinlichkeiten betrachtet. Diese hängen fast ausschließlich von der Zielauswahl ab. In Abbildung 5.35 sind die gerichteten Transitionswahrscheinlichkeiten im Vergleich zu den Transitionswahrscheinlichkeiten der Versuchspersonen aufgetragen. Die Korrelation ist mit $R^2=0.805$ schlechter als beim AIE⁺-Fahrermodell. Gravierender ist jedoch der Verlauf der Regressionsgeraden. Die Regressionsgerade des AIE⁺-Fahrermodell verlief nahezu perfekt mit einer Steigung von 1 durch den Ursprung. Das SE⁺-Fahrermodell überschätzt jedoch die Transitionswahrscheinlichkeiten zwischen dem NRBT-Display und dem Tachometer, wodurch sich die Wahrscheinlichkeit für hohe **Blickablenkungsdauern** von der Straße erheblich erhöht und zugleich die Gefahr weit von der Spurmitte abzuweichen steigt.

Zwei Gründe erscheinen plausibel für die ungünstigen Transitionswahrscheinlichkeiten:

1. Die durch den **Lowest-Ordinal-Algorithmus** geschätzten Erwartungsparameter können unpassend sein, so dass das Aufmerksamkeitsgewicht zur Straße zu gering ist.
2. Dem Fahrermodell fehlt ohne die **Ereignisfunktion** das Wissen für das geeignete Timing der Blicke. Dadurch werden unnötige Transitionen zum NRBT-Display nicht vermieden. Unnötig sind die Blicke zum NRBT-Display in dem Zeitraum kurz nach Bearbeitung einer NRBT-Ziffernfolge, in dem keine neuen Ziffernfolgen angezeigt werden.




Abbildung 5.35 – Korrelation der gerichteten Transitionswahrscheinlichkeiten des SE⁺-Fahrermodells mit den Experimentaldaten.

Um den Effekt dieser beiden Ursachen separat zu bestimmen, wurde eine weitere Variante des Fahrermodells simuliert, die im nächsten Abschnitt beschrieben wird und als S–AIE⁺-Fahrermodell (Simple AIE) bezeichnet wird.

5.8.5 S–AIE⁺-Fahrermodell

Bei dieser Variante werden die Ereignisse während der Simulation aufgezeichnet und zur Bestimmung der Erwartungsparameter verwendet, so dass eine automatische Adaption an die Ereignisraten auftritt. Allerdings werden hierzu keine Ereignisfunktion verwendet, sondern lediglich die durchschnittlichen Ereignisraten. Dies entspricht der 1. Operationalisierungsvariante der Erwartungsparameter, wie sie in Gleichung 3.6 (S. 74) dargestellt ist. Ein Vergleich des Modellverhaltens von SE⁺-Fahrermodell, S–AIE⁺-Fahrermodell und AIE⁺-Fahrermodell soll zeigen welchen Anteil das Lernen der Ereignishäufigkeiten am Fahrermodellverhalten hat und welche Verhaltensaspekte erst durch Verwendung der Ereignisfunktion entstehen. Es wurden auch mit dieser Variante für alle 12 Versuchsbedingungen je 5 Simulationen mit einer Dauer von je 125 Minuten durchgeführt, wobei die ersten 50 Minuten jeweils zum Trainieren der Ereignisraten verwendet wurden und die verbleibenden 75 Minuten für die nachfolgende Datenanalyse.

5.8.5.1 Modellanpassungsgüte

In Tabelle 5.13 sind Kennwerte der Modellanpassungsgüte für das S–AIE⁺-Fahrermodell aufgelistet. Insbesondere die Werte zum Blickverhalten sind deutlich besser als die Ergebnisse des SE⁺-Fahrermodells.

Die Überschätzung der geringen Transitionswahrscheinlichkeiten, die für das SE⁺-Fahrermodell als Ursache für die schlechtere Modellanpassung vermutet wurde, tritt beim S–AIE⁺-Fahrermodell nicht auf. In Abbildung 5.36 sind die gerichteten Transitionswahrscheinlichkeiten vergleichend für die Versuchspersonen und das S–AIE⁺-Fahrermodell aufgetragen. Die Werte gleichen annähernd den durch das AIE⁺-Fahrermodell erzielten Werten. Tatsächlich gilt dies für die meisten betrachteten Aspekte. Die in Tabelle 5.13 dargestellten Kenngrößen wurden mit leichten Abweichungen auch vom AIE⁺-Fahrermodell erzielt. Der einzige Unterschied zwischen den beiden Modellvarianten besteht darin, dass das S–AIE⁺-Fahrermodell

	R^2	RMSD	$ z $	Regressionsgerade
PDTs	0.960	0.042	0.582	$0.007 + 0.977 \cdot x$
Blickfrequenzen	0.852	0.079 Hz	0.520	$0.064 + 0.770 \cdot x$
Blickdauern	0.830	0.683 s	1.621	$0.134 + 1.060 \cdot x$
Geschwindigkeitsabweichung von 100km/h	0.540	0.846 km/h	0.614	$-0.312 + 0.859 \cdot x$
NRBT Reaktionszeit	0.176	944 ms	0.839	$2102 + 0.364 \cdot x$
Abweichung von der mittleren Spurposition	0.919	0.024 m	0.315	$-0.032 + 1.134 \cdot x$

Tabelle 5.13 – Kennwerte der Modellanpassungsgüte für das S-AIE⁺-Fahrermodell.




Abbildung 5.36 – Korrelation der gerichteten Transitionswahrscheinlichkeiten des S-AIE⁺-Fahrermodells mit den Experimentaldaten.

die durchschnittliche Ereignisrate zur Operationalisierung der Erwartungsparameter verwendet, während das AIE⁺-Fahrermodell die detaillierteren Ereignisfunktion verwendet.

Nach Estes (2002) wäre daher das S-AIE⁺-Fahrermodell dem AIE⁺-Fahrermodell vorzuziehen, da es die experimentellen Daten in gleicher Qualität aber mit weniger Annahmen erzeugt. Allerdings gibt es einen Unterschied im Modellverhalten, der das Timing der Blicke betrifft.

5.8.5.2 Timing der Blicke

In Abschnitt 5.8.2.1 wurde demonstriert, dass sowohl bei den Versuchspersonen, als auch beim AIE⁺-Fahrermodell der Anteil der Blickdatensamples, die auf das NRBT-Display gerichtet sind, in dem Zeitraum ansteigt, in dem neue Ziffernfolgen auf dem Display angezeigt werden. Allerdings ließ sich nicht unterscheiden, ob der Effekt durch die Ereignisfunktion hervorgerufen wurde, oder durch die erhöhten Blickdauern, die durch das Ablesen neuer Ziffern entstehen. Dieser Effekt tritt auch beim S-AIE⁺-Fahrermodell auf. Er ist jedoch schwächer ausgeprägt. In Abbildung 5.37(a) ist das Timing der Blicke zum NRBT-Display für das S-AIE⁺-Fahrermodell in der Art und Weise dargestellt, wie dies bereits für das AIE⁺-

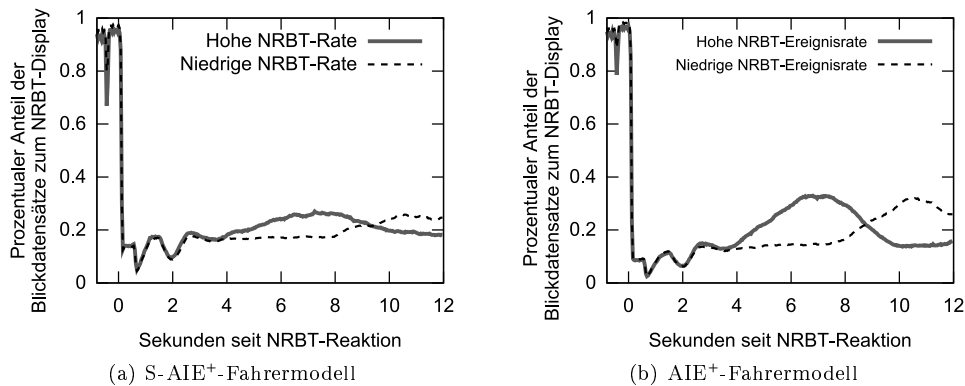


Abbildung 5.37 – Anteil der Datensamples mit Blick zum NRBT-Display nach der Reaktion auf eine neue NRBT-Ziffernfolge. Die Daten sind separat aufgetragen für die Versuchsbedingungen mit niedriger Aufgabenrate (gestrichelter Graph) und hoher Aufgabenrate (grauer, durchgezogener Graph). Links sind die Daten für das S-AIE⁺-Fahrermodell und rechts zum Vergleich die Daten des AIE⁺-Fahrermodells dargestellt

Fahrermodell geschehen ist (s. Abbildung 5.29(b)). Zum direkten Vergleich ist das Verhalten des AIE⁺-Fahrermodells hier erneut dargestellt (Abbildung 5.37(b)).

Da das S-AIE⁺-Fahrermodell keine Ereignisfunktionen verwendet, sind der Grund für den kleinen Effekt die Blickdauern. In der Versuchsbedingung mit niedriger NRBT-Aufgabenrate erscheinen neue Ziffernfolgen frühestens 3.5 s nach der letzten Ziffernfolge auf dem NRBT-Display und frühestens nach 7.5 s bei hoher NRBT-Aufgabenrate. Wenn das Fahrermodell den Blick dann auf das Display richtet, wird das Vorlesen der Ziffern und der Druck auf den Lenkradschalter simuliert. Dies benötigt Zeit, so dass die Blicke bei einer Reaktion auf eine neue Ziffernfolge länger sind. Daher steigt der Anteil der Blickdatensamples nach 3.5 bzw. 7.5 s um etwa 9 Prozentpunkte an (s. Abbildung 5.37(a)). Der Anstieg ist beim AIE⁺-Fahrermodell dagegen mit ungefähr 19 Prozentpunkten deutlich größer (s. Abbildung 5.37(b)). Dieser Effekt ist somit etwa zur Hälfte auf die erhöhten Blickdauern und zur andern Hälfte auf die erhöhte Blickfrequenz durch die Ereignisfunktionen zurückzuführen.

5.9 Zusammenfassung

In diesem Kapitel wurde die Evaluierung des AIE-Modells anhand einer Fahrsimulation präsentiert. Zu diesem Zweck wurde ein Experiment durchgeführt in dem Versuchsteilnehmer eine kurvige Strecke mit einer konstanten Geschwindigkeit von 100 km/h in einem Fahrsimulator fahren. Gleichzeitig hatten sie eine Nebenaufgabe zu bearbeiten. Während des Versuchs wurden gezielt die Ereignishäufigkeiten für die Fahraufgabe und die Nebenaufgabe, sowie die **Prioritäten** der Aufgaben variiert. Es wurde untersucht, welchen Effekt dies auf die visuelle Aufmerksamkeitsverteilung hat.

Das SEEV-Modell wurde genutzt, um die prozentualen Blickverweilzeiten (PDTs) der Versuchspersonen vorherzusagen. Die Ergebnisse wurden später mit den Ergebnissen des AIE-Modells verglichen. Hierzu wurde ein kognitives Fahrermodell in **CASCaS** entwickelt, das in dem selben Szenario simuliert wurde, in dem auch die

Versuchspersonen gefahren sind. Für die Aufmerksamkeitssteuerung des Fahrermodells wurde das AIE-Modell verwendet.

Die Daten des Fahrermodells wurden sowohl mit den Daten der Versuchspersonen, als auch mit den Vorhersagen des SEEV-Modells verglichen. Zudem wurden ähnlich wie bereits in der Studie zu Senders' Aufgabe (Kapitel 4) verschiedene Varianten des AIE-Modells verwendet und sowohl untereinander als auch mit den Daten der Versuchspersonen verglichen. Diese Untersuchungen führten u. a. zu folgenden Ergebnissen:

1. Die erwarteten Haupteffekte, die die unterschiedlichen Ereignisraten und Aufgabenprioritäten auf die PDTs und die Blickfrequenzen haben, zeigten sich größtenteils signifikant. Mit Erhöhung der Ereignisrate oder mit Erhöhung der Aufgabenpriorität stieg die Blickverteilung zur entsprechenden Informationsquelle an, während sie für die anderen Informationsquellen abnahm.
2. Die PDTs der Versuchspersonen ließen sich gut mit dem SEEV-Modell vorhersagen und unterstützen damit die Ergebnisse, die Horrey et al. (2005) in einer ähnlichen Studie erzielt haben.
3. Bei der Parameterschätzung für die freien Parameter des Fahrermodells hat sich gezeigt, dass die Dauer der benötigten Lernphase des AIE-Modells eine effiziente Anpassung der Parameter an die Experimentaldaten erschwert.
4. Ohne Verwendung des AIE-Modells ist die Modellanpassungsgüte des Fahrermodells sowohl bezüglich des Blickverhaltens, als auch bezüglich des Fahrverhaltens sehr schlecht. Insbesondere hat das Fahrermodell bei dieser Variante Probleme das Fahrzeug innerhalb der Spur zu halten.
5. Das Fahrermodell ist bei Verwendung des AIE-Modells in der Lage, die PDTs in nahezu gleicher Qualität wie das SEEV-Modell vorherzusagen. Im Gegensatz zum SEEV-Modell ermöglicht es das AIE-Modell, noch weitere Aspekte des Blickverhaltens zu bestimmen, wie Blickfrequenzen und Transitionswahrscheinlichkeiten. Jedoch wiesen die Blickfrequenzen eine etwas geringere Korrelation auf als die PDTs. Auch einige Aspekte der Aufgabenbearbeitung ließen sich durch das Fahrermodell vorhersagen. Allerdings war die Modellanpassungsgüte für die Longitudinalkontrolle und die Nebenaufgabe deutlich schlechter als für das Blickverhalten und die Lateralkontrolle.
6. Ein Vergleich zwischen der additiven und der multiplikativen Formulierung des AIE-Modell zeigte, dass die Modellanpassungsgüte des Blickverhaltens des Fahrermodells bei der additiven Variante etwas besser ist als bei der multiplikativen Variante. Dieses Ergebnis ist konsistent mit den Beobachtungen im vorherigen Kapitel zu Senders' Aufgabe.
7. Bei einer Konfiguration des Aufmerksamkeitsmodells ähnlich wie in MIDAS, bei der statische Erwartungsparameter auf Basis des Lowest-Ordinal-Algorithmus verwendet werden (SE⁺-Fahrermodell), zeigte sich eine schlechte Modellanpassungsgüte bei fast allen untersuchten Aspekten. Es zeigte sich, dass insbesondere die simulierten Transitionswahrscheinlichkeiten unpassend waren und die Lateralkontrolle des Fahrermodells sehr sensitiv auf diese reagierte.

8. Das S-AIE⁺-Fahrermodell verwendet quasi-statische Erwartungsparameter, die sich aus den durchschnittlichen Ereignisraten der jeweiligen Aufgaben ergeben. Dabei wurden Modellanpassungsgüten für die untersuchten Aspekte des Blick- und Fahrverhaltens erzielt, die beinahe so gut sind, wie die des AIE⁺-Fahrermodells. Das Wissen über die Ereignishäufigkeiten für die einzelnen Aufgaben scheint daher wichtiger für ein realistisches Fahrerverhalten zu sein, als die Repräsentation dieser Häufigkeiten in Form von [Ereignisfunktion](#).
9. Das S-AIE⁺-Fahrermodell zeigte sich für die meisten Aspekte bereits als ausreichend. Ein Aspekt, der sich bei der Verwendung der Ereignisfunktionen mit dem AIE⁺-Fahrermodell verbessern ließ, bezieht sich auf das Timing der Blicke. Dieses konnte durch die Ereignisfunktionen besser abgestimmt werden.
10. Die Lerngeschwindigkeit der Ereignisfunktionen lässt sich über Potenzfunktionen der Form $a \cdot x^{-b}$ beschreiben. Die hier ermittelte Lerngeschwindigkeit von $b = 0.418$ ist etwas geringer als die erwartete Geschwindigkeit von $b = 0.5$. Der erzielte Wert liegt jedoch konsistent in dem Bereich der Lerngeschwindigkeiten, die bei den Untersuchungen zu Senders Aufgabe im vorherigen Kapitel erreicht wurden.

Generell ließ sich das Verhalten der Versuchspersonen mit dem AIE-Modell gut wiedergeben. Allerdings wies das Verhalten der Versuchspersonen auch einige Aspekte auf, die nicht durch das AIE-Modell nachgebildet werden. Insbesondere scheint sich der Effekt der Ereignisraten und Aufgabenprioritäten nicht nur auf den [Ablaufplanungsalgorithmus](#) und damit die Blickfrequenzen zu beschränken, sondern zum Teil auch auf den [Datenakquisealgorithmus](#), der die Blickdauern einzelner Blicke bestimmt. Die Blickdauern der Versuchspersonen zu einer Informationsquelle reduzieren sich, wenn sich die Aufmerksamkeitsgewichte der anderen Informationsquellen erhöhen. Es wird hier vermutet, dass die Versuchspersonen in der Lage sind, in einer solchen Situation die Aufgabe, die mit der jeweiligen Informationsquelle verbunden ist, schneller oder weniger präzise durchzuführen. Dadurch verringern sich die Blickdauern. Da weder das AIE-Modell noch CASCaS einen entsprechenden Mechanismus besitzt, wurden diese Effekte vom Fahrermodell nicht wiedergegeben. Hier wäre es für zukünftige Arbeiten interessant, diesen Aspekt gezielt zu untersuchen und gegebenenfalls ein geeignetes Modell des Datenakquisealgorithmus in der kognitiven Architektur zu integrieren.

Kapitel 6

Zusammenfassung und Diskussion

6.1 Zusammenfassung

In dieser Arbeit wurde mit dem Adaptive Information Expectancy (AIE) Modell ein Modell zur Simulation menschlicher Aufmerksamkeitsverteilung konzeptioniert und anhand zweier Anwendungsfälle evaluiert. Das AIE-Modell liefert einen neuen Beitrag im Bereich der künstlichen Intelligenz. Es ermöglicht, die Aufmerksamkeitsverteilung von Autofahrern detaillierter als bisher zu simulieren. Das Konzept des AIE-Modells sieht vor, dass es in eine kognitive Architektur integriert wird. Dadurch lässt es sich nicht nur für Fahrermodelle, sondern für unterschiedliche kognitive Agenten verwenden.

Das AIE-Modell baut auf existierenden Modellen der Aufmerksamkeitsverteilung in Multitasking-Situationen auf, bei denen mehrere Informationsquellen gleichzeitig beobachtet werden müssen. Die im **SEEV**-Modell aufgelisteten Top-Down-Faktoren *Ereigniserwartung* und *Informationswert* sind die Einflussfaktoren des AIE-Modells. Es simuliert daher nur die wissensgetriebene (**Top-Down**) Aufmerksamkeitsverteilung.

Nach dem Modell zur visuellen Aufmerksamkeitsverteilung von **Carbonell (1966)** wächst die Unsicherheit eines Beobachters über den Zustand einer Informationsquelle immer weiter, je länger die Informationsquelle nicht betrachtet wurde. Die Unsicherheit nimmt bei Informationsquellen mit hoher **Bandbreite** schneller zu. Basierend auf diesem Ansatz steigt auch die Ereigniserwartung im AIE-Modell seit der Wahrnehmung des letzten **Ereignisses** mit voranschreitender Zeit immer weiter an und zwar umso schneller, je höher die **Ereignisrate** für eine Informationsquelle ist.

Das AIE-Modell definiert Ereignisse über das Aufgabenmodell des kognitiven Agenten. Verwendet der kognitive Agent Informationen, um ein Ziel zu erreichen, so wird von einem Ereignis gesprochen. Bei der in dieser Arbeit vorgenommenen exemplarischen Implementierung des AIE-Modells in der kognitiven Architektur **CASCaS**, lassen sich Ereignisse über das Feuern von Produktionsregeln des Aufgabenmodells bestimmen. Da sich die Theorien vieler kognitiver Architekturen ähneln (**Taatgen und Anderson, 2010**), sollte sich das AIE-Modell auch in andere kognitive Architekturen integrieren lassen. Dadurch lässt sich die menschliche Aufmerksamkeitsverteilung im Zusammenwirken mit anderen Aspekten der Kognition und der Interaktion

mit der Umwelt untersuchen.

Um den Anstieg der Erwartung zu bestimmen, zeichnet das AIE-Modell die Verteilung der Ereignisabstände aus dem bisherigen Simulationsverlauf in Form von kumulierten Verteilungsfunktionen auf, die als **Ereignisfunktion** bezeichnet werden. Mit Hilfe der Ereignisfunktionen wird der Erwartungsfaktor automatisch bestimmt und die Aufmerksamkeitsverteilung passt sich automatisch an die Ereignisabstandsverteilung im aktuellen Simulationsszenario an. Dies ist eine Erweiterung gegenüber der vergleichbaren Integration des **SEEV**-Modells in die kognitive Architektur **MIDAS** (Gore et al., 2009), bei der die Erwartungsfaktoren vorab manuell festgelegt werden und sich nicht dynamisch ändern. Dadurch wird die Anzahl an freien Parametern verringert. Das ist generell wünschenswert, da nach dem Sparsamkeitsprinzip (auch Ockham's Rasiermesser) bei der Wahl zwischen vergleichbaren Modellen das einfachere, mit weniger freien Parametern bevorzugt werden sollte (MacKay, 2005).

Das AIE-Modell wurde anhand von zwei Studien evaluiert. Für die erste Studie wurden Ergebnisse aus Arbeiten herangezogen, die von Senders (1983) an einer Laboraufgabe durchgeführt wurden. Mit dieser Aufgabe wurde gezielt der Zusammenhang zwischen Ereignisraten mehrerer Anzeigeeinstrumente und der Blickfrequenz von menschlichen Beobachtern untersucht. In einem weiteren Schritt wurde im Rahmen dieser Arbeit eine Fahrstudie durchgeführt, mit der die Eignung des AIE-Modells zur Verwendung innerhalb eines kognitiven Fahrermodells untersucht wurde.

Für beide Studien wurde jeweils ein kognitiver Agent in CASCaS entwickelt. Zur Untersuchung des AIE-Modells wurden die Agenten mit unterschiedlichen Varianten des AIE-Modells simuliert.

1. Über die als AIE⁺ und AIE* bezeichneten Varianten des AIE-Modells wurde ein Vergleich zwischen den in der Literatur vorgefundenen additiven und multiplikativen Verknüpfungen der Wert- und Erwartungsfaktoren vorgenommen.
2. Das AIE-Modell wurde verglichen mit einer Variante, bei der statische Erwartungsparameter (SE-Variante) anstelle der dynamischen Bestimmung über die Ereignisfunktionen verwendet wurden. Dies entspricht dem Ansatz zur Integration des **SEEV**-Modells in die kognitive Architektur **MIDAS**.
3. Die S-AIE-Variante, bei der keine Ereignisfunktionen sondern lediglich die durchschnittlichen Ereignisraten zur Adaption des Blickverhaltens genutzt wurden, wurde simuliert, um zu ermitteln, welche Effekte durch das Lernen der Ereignishäufigkeiten entstehen und welche auf die Repräsentation der Ereignishäufigkeiten als Ereignisfunktion zurückzuführen sind.
4. Es wurde zudem ein Vergleich zur bisherigen CASCaS-Implementierung vorgenommen (-AIE-Variante).
5. Für die Studie von Senders wurde eine Sensitivitätsanalyse für das Verhältnis der Gewichtung der Erwartungs- und Wertfaktoren vorgenommen. Dieses Verhältnis stellt den einzigen freien Parameter des AIE-Modells dar.

Die unterschiedlichen Modellvarianten führten zu unterschiedlichem Verhalten der kognitiven Agenten.

1. In beiden Studien war die Modellanpassungsgüte bei additiver Verknüpfung der Erwartungs- und Wertparameter (AIE⁺) besser als bei multiplikativer Verknüpfung (AIE^{*}). Dies deckt sich mit Ergebnissen von [Wickens et al. \(2008, S. 231 f.\)](#) und [Byrne und Kirlik \(2004, S. 61\)](#) zum SEEV-Modell. In den beiden Studien der vorliegenden Arbeit war die Korrelation zwischen dem Blickverhalten der Versuchspersonen und des kognitiven Agenten bei beiden Modellvarianten (AIE⁺ und AIE^{*}) gut, allerdings waren die absoluten Abweichungen zu den Werten der Versuchspersonen größer bei der multiplikativen Variante. Insbesondere wurde die Aufmerksamkeitsverteilung zu Informationsquellen mit hoher Ereignishäufigkeit von der multiplikativen Variante überschätzt und zu Informationsquellen mit niedriger Ereignisrate unterschätzt. Dies ist ebenfalls konsistent zu Ergebnissen in der Literatur. Die Korrelationsgeraden zu vorhergesagten und beobachteten PDTs in Studien von [Wickens et al. \(2004, S. 25\)](#), [Wickens et al. \(2003a\)](#), mit Ausnahme von Experiment 3) und [Horrey et al. \(2005\)](#) zu Piloten- und Fahrerverhalten weisen ebenfalls diesen Effekt in unterschiedlich starker Ausprägung bei der multiplikativen Variante auf.
2. Bei Verwendung statischer Parameter (SE) ließen sich in den beiden Studien unterschiedliche Beobachtungen machen. Für Senders Aufgabe waren die Ereignisraten der Informationsquellen bekannt und wurden direkt verwendet, um die Erwartungsparameter zu bestimmen. Die erzielten Vorhersagen zu Blickfrequenzen und PDTs waren beinahe identisch zu den Vorhersagen, die das AIE-Modell lieferte. Das heißt, in diesem Szenario war das Lernen der Ereignishäufigkeiten und die entsprechende Anpassung des Blickverhaltens gar nicht nötig. Im Gegenteil, es stellt eher einen zusätzlichen Aufwand dar.
Beim Fahrermodell war dagegen die Modellanpassungsgüte bei Verwendung statischer Erwartungsparameter deutlich schlechter als bei Verwendung des vollständigen AIE-Modells. Zudem zeigte sich ein sehr instabiles Fahrverhalten. Ursache ist hier, dass die Ereignisraten nicht bekannt waren und die Erwartungsparameter daher über den von [Wickens et al. \(2001\)](#) vorgeschlagenen [Lowest-Ordinal-Algorithmus](#) geschätzt wurden.
3. Wie wichtig eine gute Schätzung der Erwartungsparameter ist, zeigte sich bei Simulation des S-AIE-Modells in der Fahrsimulatorstudie. Nach ausreichender Trainingszeit ist die ermittelte Ereignisrate quasi statisch und das Modell daher ähnlich zur SE-Variante. Dennoch zeigte sich eine deutlich bessere Modellanpassungsgüte als bei Verwendung des Lowest Ordinal Algorithmus. Sie gleicht beinahe der Modellanpassungsgüte des vollständigen AIE-Modells. Lediglich beim Timing der Blicke zur Nebenaufgabe ließ sich erkennen, dass das Verhalten der Versuchspersonen besser durch die AIE-Variante als durch die S-AIE-Variante wiedergegeben wird. Die dynamische Adaption der Aufmerksamkeitsverteilung an die beobachteten Ereignisraten scheint also vor allem in Szenarien hilfreich zu sein, in denen die Ereignisraten nicht vorab bekannt sind.
4. Beide Studien waren so ausgelegt, dass die Ereignishäufigkeiten der Informationsquellen relevant für die Aufgabenbearbeitung sind. Da die bisherige Implementierung von CASCaS Ereignishäufigkeiten nicht berücksichtigt, war bei den Simulationen ohne AIE-Modell die Anpassungsgüte für beide Studien schlecht. Die Integration des AIE-Modells in CASCaS hat die Güte der Simulationsergebnisse in beiden Szenarien verbessert.

5. Die Sensitivitätsanalyse wurde nur für Senders Aufgabe durchgeführt, da der zeitliche Aufwand für die Fahrsimulation wesentlich größer ist. Die beste Modellanpassungsgüte wurde ungefähr bei einem 1:1-Verhältnis der Gewichtung der Erwartungsparameter zur Gewichtung der Wertparameter beobachtet. Dies deckt sich mit der Art und Weise in der das SEEV-Modell in der Literatur Verwendung findet.

Ein weiterer Aspekt des AIE-Modells, der untersucht wurde, betrifft die Lerngeschwindigkeit der Ereignisfunktionen. Das AIE-Modell lernt die Erwartungsparameter, indem es die Verteilung der Ereignisabstände beobachtet und in den Ereignisfunktionen speichert. Das Erlernen der Ereignisfunktionen ermöglicht zwar eine automatische Bestimmung der Erwartungsparameter, allerdings erfordert es zusätzliche Simulationszeit. Daher ist es wünschenswert, dass die Ereignisfunktionen während der Lernphase schnell gegen eine stabile Grenzfunktion konvergieren. Das Konvergenzverhalten der Ereignisfunktionen wurde untersucht, indem mehrere Langzeitsimulationen der Agenten durchgeführt wurden. Die sich dabei entwickelnden Ereignisfunktionen wurden untereinander verglichen. Es wurde erwartet, dass diese mit einer Geschwindigkeit von $a \cdot t^{-\frac{1}{2}}$ gegen eine gemeinsame Grenzfunktion konvergieren, wobei Abweichungen in der Konvergenzgeschwindigkeit durch Rückkopplungen im AIE-Modell entstehen können. Für die AIE⁺-Variante ergaben sich für die Fahrsimulation und die drei Konfigurationen von Senders Aufgabe Konvergenzgeschwindigkeiten nahe des erwarteten Wertes (0.5) im Bereich von 0.415 bis 0.465. Für die AIE^{*}-Variante wurden niedrigere Geschwindigkeiten im Bereich von 0.347 bis 0.417 gemessen.

6.2 Diskussion

Es soll nun ein kritischer Blick auf die erzielten Ergebnisse geworfen werden. Zuerst wird eine Charakterisierung des AIE-Modells und der in dieser Arbeit untersuchten Studien vorgenommen, um einen Bezug zu ähnlichen Studien und Modellen herzustellen. Anschließend werden einzelne Aspekte der Arbeit diskutiert. Dabei werden Wege für zukünftige Arbeiten und mögliche Ansätze zur Integration verwandter Modelle aufgezeigt.

6.2.1 Charakterisierung der Studien

Das AIE-Modell beschäftigt sich mit der nebenläufigen Bearbeitung mehrerer Aufgaben. Die zur Evaluierung herangezogenen Aufgaben decken jedoch nur einen kleinen Teil möglicher Anwendungsszenarien ab. Zudem konzentriert sich das AIE-Modell auf die Frage, warum der Fokus der Aufmerksamkeit zu einem Zeitpunkt auf eine bestimmte Aufgabe gerichtet ist. Dies wird über die beiden Einflussfaktoren Wert und Erwartung bestimmt. Es geht jedoch nicht darauf ein, wie der Wechsel der Aufgaben stattfindet. Andere Arbeiten im Multitasking-Umfeld wie die Threaded Cognition Theorie (Salvucci und Taatgen, 2011) und die Multiple Resource Theorie (Wickens, 2008) gehen darauf detaillierter ein und erklären, in welchen Situationen sogar eine überlappende Ausführung von Aufgaben möglich ist. Salvucci und Taatgen (2011, S.8ff.) stellen drei Kontinua zur Charakterisierung von Multitasking Studien vor (s. Abbildung 6.1). Über das Abstraktionskontinuum wird das Abstraktionslevel der untersuchten Multitasking-Modelle beschrieben. Die Aufgaben, die in Studien zur Untersuchung der Modelle herangezogen werden,

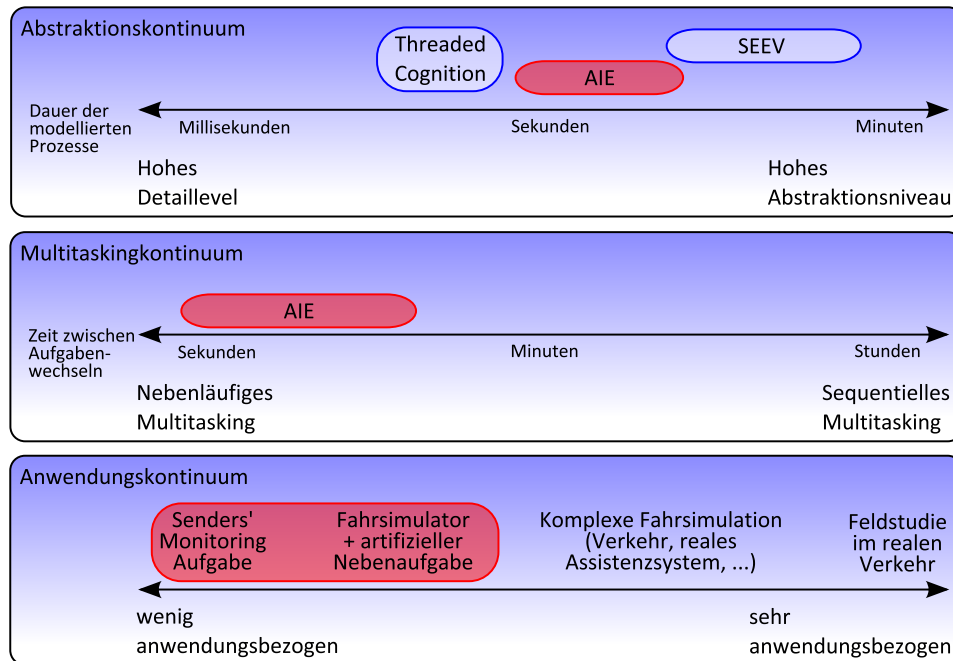


Abbildung 6.1 – Einordnung des AIE-Modells (rot) in die drei von [Salvucci und Taatgen \(2011\)](#) vorgeschlagenen Kontinua.

werden über das Anwendungs- und das Multitaskingkontinuum charakterisiert, indem die Anwendungsnahe der Aufgaben und die Häufigkeit von Aufgabenwechseln angegeben wird.

Abstraktionskontinuum. Das **SEEV**-Modell sagt prozentuale Blickverweilzeiten vorher. Das ist eine aggregierte Größe des Blickverhaltens. Das **AIE**-Modell ermöglicht es dagegen, auch die Blicksequenzen vorherzusagen, die zu den prozentualen Blickverweilzeiten führen. Es befindet sich daher auf einem niedrigerem Abstraktionsniveau als das **SEEV**-Modell.

Eine Skala, mit der sich einordnen lässt, auf welchem Abstraktionslevel menschliches Verhalten modelliert wird, wird von [Newell \(1990, S. 121 ff.\)](#) eingeführt. Newells Skala ist in mehrere Bänder unterteilt. Auf der untersten Ebene befindet sich das biologische Band. Diesem werden die Prozesse zugeordnet, die sich in einzelnen Neuronen oder kleinen neuronalen Netzen in Bruchteilen einer Millisekunde bis hin zu wenigen Millisekunden abspielen. Über dem biologischen Band befindet sich das kognitive Band, dem Prozesse in einer Größenordnung von wenigen Millisekunden bis zu wenigen Sekunden zugeordnet werden. Dazu zählen einfache Operationen wie das Drücken einer Taste. Am oberen Ende dieses Bandes ordnet [Newell \(1990, S. 141\)](#) Unit Tasks an. Den Begriff Unit Task verwenden [Card et al. \(1983\)](#), um die kleinsten Aufgabeneinheiten zu beschreiben, die von menschlichen Akteuren bei einer Aufgabenanalyse identifiziert werden. Dem nächsthöheren Band (rationales Band) werden komplexere Aufgaben zugeordnet, die einige Sekunden oder bis zu mehrere Stunden dauern können. Da das **AIE**-Modell die Ablaufplanung für Aufgabeneinheiten mehrerer Aufgaben übernimmt, ist es auf Newells Skala etwa zwischen dem kognitiven und dem rationalen Band ange-

ordnet.

Das Threaded Cognition Modell lässt sich auf einem niedrigeren Abstraktionslevel ansiedeln, da es die Prozesse bei Aufgabenwechseln beschreibt. Es beschreibt jedoch nicht, wann ein Aufgabenwechsel stattfindet.

Multitaskingkontinuum. Immer wenn ein Aufgabenwechsel möglich ist, wählt das AIE-Modell das nächste Aufgabenziel aus. Dies führt zu sehr häufigen Aufgabenwechseln, wie es sowohl in Senders Studien als auch in der Fahr Simulatorstudie zu sehen ist. Die Studien lassen sich daher am äußeren Ende des Kontinuums beim nebenläufigen Multitasking einordnen.

Anwendungskontinuum. In den Studien zu Senders Aufgabe wird eine sehr kontrollierte Laboraufgabe untersucht. Sie ist wenig anwendungsnah und befindet sich daher am äußeren Ende des Anwendungskontinuums. Die Fahr Simulatorstudie stellt dagegen ein Szenario dar, das anwendungsnäher ist. Allerdings wurde ein sehr einfaches Szenario gewählt, das die Komplexität von realen Fahrsituationen nicht vollständig widerspiegelt. Die Fahraufgabe ist begrenzt auf die Kontrolle des Fahrzeugs und spielt sich damit hauptsächlich auf einer der drei Ebenen des Fahrverhaltens ab, die von Michon (1985) identifiziert wurden. Die strategische und taktische Ebene wird kaum berührt. Auch bei der Nebenaufgabe (NRBT) handelt es sich um eine sehr kontrollierte Laboraufgabe, die in der Realität nicht in dieser Form zu finden ist. Zudem wurde das Verhalten von Versuchspersonen in einem Fahr Simulator untersucht und nicht von Fahrern im realen Verkehr. Die Versuchspersonen wurden instruiert alle drei Aufgaben möglichst präzise auszuführen. Ohne diese Instruktionen kann eine größere Verhaltensvariabilität erwartet werden, wie größere Geschwindigkeitsunterschiede oder das Schneiden von Kurven.

Auch wenn es sich hier um eine realistische Fahr Simulation handelt, so wurde das Szenario dennoch stark kontrolliert. Es lassen sich realistischere und anwendungsnähere Szenarien in Fahr Simulationen umsetzen.

Die Einordnung dieser Arbeit in diese drei Kontinua ist in Abbildung 6.1 grafisch dargestellt. Bei Betrachtung des Anwendungskontinuums ist gut zu erkennen, dass für zukünftige Arbeiten insbesondere die Untersuchung von anwendungsnäheren Studien interessant ist. Dies können zum Beispiel Szenarien mit anderen Verkehrsteilnehmern oder komplexeren Fahrmanövern sein, bis hin zu Vergleichen mit Fahrern im realen Straßenverkehr.

Im Abstraktionskontinuum sind zwei Modelle eingetragen, die eng mit dem AIE-Modell verwandt sind. Das Verhältnis zum SEEV-Modell ist leicht ersichtlich, da die Verwendung der Wert- und Erwartungsparameter im AIE-Modell auf den Top-Down-Parametern des SEEV-Modells beruhen. Im Vergleich zum SEEV-Modell ist das AIE-Modell jedoch in der Lage, detailliertere Vorhersagen auf dem Detaillevel einzelner Fixationswahrscheinlichkeiten zu machen. Zudem erlaubt es die Interaktion zwischen Aufgabenbearbeitung und Aufmerksamkeitsverteilung zu untersuchen. Allerdings gibt es einen großen Nachteil im Vergleich zum SEEV-Modell. Das SEEV-Modell ist einfach und schnell anwendbar. Das AIE-Modell dagegen erfordert weitere Komponenten: ein Simulationsmodell der Umgebung, ein Aufgabenmodell und eine kognitive Architektur zur Ausführung des Aufgabenmodells. Das resultiert in einem komplexeren Gesamtmodell, bei dem viel Zeit in die Entwicklung und Simulation fließt. Von einem Anwenderstandpunkt aus stellt das AIE-Modell daher eher eine Alternative zum SEEV-Modell dar als eine Verbesserung, da zwi-

schen einer einfacher Anwendung und detaillierten Ergebnissen abgewägt werden muss.

Auch zum Threaded Cognition Modell lässt sich ein Verhältnis herstellen, das für Untersuchungen in späteren Arbeiten interessant ist. Der Fokus des Threaded Cognition Modells liegt zwar darauf, zu simulieren, wie mehrere Tasks, die unterschiedliche Ressourcen benötigen, zeitlich überschneidend gleichzeitig bearbeitet werden können. Voraussetzung für eine zeitlich überschneidende Bearbeitung zweier Aufgaben ist jedoch, dass beide innerhalb kurzer Zeit Zugriff auf die exklusive Ressource der prozeduralen Wissensverarbeitung haben. Wenn jedoch zwei oder mehr Tasks gleichzeitig Zugriff auf die prozedurale Ressource haben wollen, so wählen [Salvucci und Taatgen \(2011, S. 48f.\)](#) in dem Konfliktauflösungsprinzip der Threaded Cognition immer den dringendsten Taskthread. Sie schlagen vor, dass die Dringlichkeit vom Modellierer am Aufgabenmodell annotiert wird, indem jede Aufgabe, nachdem sie bearbeitet wurde, den Zeitpunkt angibt, an dem sie erneut bearbeitet werden soll.

An dieser Stelle kann nun das AIE-Modell zur Implementierung des Konfliktauflösungsprinzips verwendet werden, um die Dringlichkeit einer Aufgabenbearbeitung automatisch und detaillierter zu bestimmen. Für zukünftige Arbeiten ist es daher interessant, kognitive Agenten in einer kognitiven Architektur zu untersuchen, die ein solches integriertes Modell aus Threaded Cognition und AIE-Modell beinhaltet. Das Threaded Cognition Modell wurde in [ACT-R](#) implementiert. [ACT-R](#) erfüllt zudem die in Abschnitt 3.6.5 aufgelisteten Anforderungen, die das AIE-Modell an eine kognitive Architektur stellt. Damit stellt [ACT-R](#) einen geeigneten Kandidaten dar, um die Kombination beider Modelle zu untersuchen.

6.2.2 Verwendung der Ereignisfunktionen

Die Untersuchungen des Fahrermodells haben gezeigt, dass sich die Erwartungsparameter gut durch das Lernen der [Ereignisraten](#) bestimmen lassen. Beim Vergleich der SE^+ -Variante mit der $S-AIE^+$ -Variante zeigte sich zudem, dass bei dem hier verwendeten Fahrermodell die Operationalisierung der Erwartungsparameter entscheidend für ein stabiles Fahrverhalten ist. Allerdings zeigte sich beim Vergleich des $S-AIE^+$ -Fahrermodells mit dem AIE^+ -Fahrermodell, dass die Operationalisierung der Erwartungsparameter über die eingeführten [Ereignisfunktion](#) nicht notwendig für ein stabiles Fahrverhalten ist. Hierfür reichte eine einfache Operationalisierung über die durchschnittliche Ereignisrate.

Ziel dieser Arbeit ist die Erstellung eines geeigneten Aufmerksamkeitsmodells für ein kognitives Fahrermodell. Für das hier untersuchte Szenario scheint die $S-AIE^+$ -Variante ausreichend zu sein. Die komplexere Modellstruktur, die bei Verwendung der Ereignisfunktionen entsteht, führte zu keiner Verbesserung der Modellanpassungsgüte für die hier untersuchten Aspekte des Fahrverhaltens.

Allerdings ließ sich mit den Ereignisfunktionen ein realistischeres Blickverhalten erzeugen. Dies zeigte sich am Timing der Blicke zum NRBT-Display. Bei komplexeren Fahrmanövern mit viel Verkehr, wie das Passieren einer Kreuzung oder das Wechseln der Spur, lässt sich vermuten, dass das Timing der Blicke eine höhere Relevanz für das Fahrverhalten hat, als in dem hier untersuchten Szenario. Bei komplexeren Manövern stellt sich jedoch nicht nur die Frage, ob die Ereignisfunktionen hilfreich sind, sondern auch, ob sie ausreichend sind. Die Ereignisfunktionen werden aus den beobachteten Ereignisabständen gebildet. Es lassen sich typischerweise jedoch noch weitere Quellen für Erwartung identifizieren. [Wickens und McCarley \(2008\)](#) geben hier neben der Ereignisrate auch Hinweise aus der Umgebung als Quelle für Erwar-

tung an. In einer Studie zu Senders' Aufgabe konnten [Bohnen et al. \(1996\)](#) beispielsweise zeigen, dass auch die Nähe des Instrumentenzeigers zum Alarmbereich mit der Blickablenkungsdauer korreliert. Je dichter der Zeiger am Alarmbereich war, desto schneller wurde das Instrument erneut betrachtet. Ähnliche Effekte lassen sich auch beim Autofahren erwarten. So könnte zum Beispiel die Geschwindigkeit anderer Verkehrsteilnehmer, der Abstand zu einer Kreuzung oder das Aufleuchten von Blink- oder Bremsleuchten die Erwartungshaltung des Fahrers für zukünftige Ereignisse beeinflussen. Um dies zu untersuchen, bedarf es jedoch weiterer Studien. Für zukünftige Arbeiten ist eine Generalisierung des AIE-Modells denkbar, bei der auch Umgebungshinweise berücksichtigt werden. Eine Möglichkeit besteht darin, bei der Beobachtung von [Ereignissen](#) nicht nur den jeweiligen Zeitabstand zum vorherigen Ereignis aufzuzeichnen, sondern auch alle anderen relevanten Umgebungshinweise. So kann das Modell prinzipiell lernen, wie durch diese Hinweise die Ereignisabstände beeinflusst werden. Allerdings besteht die Möglichkeit, dass aufgrund der komplexeren Datenstruktur längere Lernphasen nötig sind. Zudem hängt es von der jeweiligen Aufgabe ab, welche Umgebungshinweise die Erwartung beeinflussen. Die relevanten Hinweise lassen sich daher nicht automatisch bestimmen, sondern müssen vom Modellierer identifiziert werden. Sie könnten analog zu den Wertparametern an die Aufgabenprozedur annotiert werden. Für das Abstandhalten zu einem vorausfahrenden Fahrzeug könnte zum Beispiel der aktuelle Zeitabstand oder das Aufleuchten der Bremslichter relevant für neue Ereignisse sein:

Prozedurabschnitt 6.1 – Mögliche Annotation des Zeitabstands und des Bremslichtstatus des vorausfahrenden Fahrzeugs an eine Aufgabenprozedur.

```
Goal, name=keep_distance, mode=persistent, value=1.0,
  expectancy_cues={leading_vehicle.time_headway, leading_vehicle.brake_light}
```

6.2.3 Gewichtung von Ereignissen

Bei der Bestimmung des Erwartungsparameters wird jedes bisher beobachtete [Ereignis](#) gleich stark gewichtet. Das ist eine vereinfachende Abstraktion. Es gibt gute Gründe anzunehmen, dass Ereignisse unterschiedlich stark gewichtet werden sollten.

6.2.3.1 Stärke der Ereignisausprägung

In dem hier untersuchten Fahrermodell wurden Ereignisse für das Ziel der Lateralkontrolle über die Stabilitätsschwellenwerte bezüglich der Abweichung von der Spurmitte und der Zeit bis zur Überquerung der Spurbegrenzung (TLC) bestimmt (s. Abschnitt 5.6.1). Im Fahrermodell existiert daher eine klare Grenze, wann ein Ereignis auftritt und wann nicht. In der Realität ist das so jedoch nicht zu erwarten. Wenn die TLC nur noch eine Sekunde beträgt, so kann man erwarten, dass ein solches Ereignis kritischer ist als eine TLC von drei Sekunden, und somit einen stärkeren Einfluss hat.

Generell stellt sich die Frage, ob Ereignisse, die durch einen Schwellenwert in der Aufgabenprozedur definiert sind, stärker gewichtet werden sollen, je stärker die Ausprägung des jeweiligen Ereignisses ist, d. h. je weiter der beobachtete Wert vom Schwellenwert abweicht.

6.2.3.2 Adaptivität

Da das AIE-Modell die Ereigniserwartung eines kognitiven Agenten während der Simulation dynamisch schätzt, kann die Aufmerksamkeitsverteilung des kognitiven Agenten automatisch an unterschiedliche Situationen adaptiert werden. Die Adaption ist jedoch nur bedingt möglich. Das AIE-Modell geht davon aus, dass sich die Verteilung der Ereignisabstände in der Umgebung des kognitiven Agenten während eines Simulationslaufes nicht ändert. Die Aufmerksamkeitsverteilung passt sich an diese eine Ereignisabstandsverteilung an. Ändert sich eine Ereignisabstandsverteilung während eines Simulationslaufes, so kann das AIE-Modell darauf nur schlecht reagieren. Die geänderte Verteilung der Ereignisabstände führt dazu, dass sich auch die [Ereignisfunktion](#) ändern. Allerdings sind in einem solchen Fall in der Ereignisfunktion [Ereignisse](#) aus der ursprünglichen und der geänderten Ereignisabstandsverteilung enthalten.

In der Realität kann man erwarten, dass eine Änderung der Ereignisabstandsverteilung vom Menschen wahrgenommen wird und sich seine mentale Repräsentation der Ereignisabstände ändert. Modelle, die beschreiben, wie sich die eigene Meinung über den Zustand der Umgebung über die Zeit ändern kann, sind zum Beispiel das Belief-Adjustment-Modell ([Hogarth und Einhorn, 1992](#)) oder das Quantum-Inference-Modell ([Trueblood und Busemeyer, 2011](#)). Dabei stellen kürzlich beobachtete Indizien über den Zustand der Umgebung am ehesten den Ist-Zustand dar und werden bei der Meinungsbildung stärker gewichtet als Indizien, deren Beobachtung länger zurück liegt. Dies wird als Recency-Effekt bezeichnet. Mit dieser Argumentation kann auch die Hypothese aufgestellt werden, dass die zuletzt wahrgenommenen Ereignisabstände am besten den Ist-Zustand der Ereignisabstandsverteilung darstellen und daher stärker gewichtet werden sollten als länger zurückliegende. Um dies zu untersuchen, bedarf es jedoch weiterer Studien.

6.3 Fazit

In den vorherigen Kapiteln wurde gezeigt, dass sich mit dem AIE-Modell in den untersuchten Szenarien gute Ergebnisse erzielen ließen. Diese befinden sich im Anwendungskontinuum eher im Bereich der Laboruntersuchungen als im Bereich sehr anwendungsnaher Untersuchungen. Im Hinblick auf die hier angesprochenen Diskussionspunkte muss sich noch zeigen, in wie weit das AIE-Modell in anderen Szenarien verwendbar ist, und ob weitere Aspekte wie Umgebungshinweise oder Recency-Effekte berücksichtigt werden müssen. Es besteht also ein großer Raum für zukünftige Arbeiten, die auf dem AIE-Modell aufsetzen.

Das AIE-Modell demonstriert, wie die Aufgabenbearbeitung und die Aufmerksamkeitsverteilung eng miteinander interagierend simuliert werden können. Die Simulation lässt sich dabei detaillierter durchführen, als es mit bisherigen State-of-the-Art-Modellen möglich ist. Allerdings erfordert diese Erhöhung des Detaillierungsgrades auch einen erhöhten Modellierungs- und Simulationsaufwand. Der größte praktische Nutzen des AIE-Modells ist daher in Anwendungsfällen zu sehen, bei denen eine sehr gründliche Untersuchung der Aufmerksamkeit gewünscht ist.

Anhang A

Formale Semantik des AIE-Modells

Die nachfolgenden Algorithmen 1 bis 5 beschreiben die Simulation des AIE-Modells. Der Einstiegspunkt der Simulation ist die Funktion `PROCESSGOALAGENDA` (Algorithmus 1), die die Endlosschleife einer kognitiven Architektur beinhaltet, in der die Auswahl des aktuellen Ziels auf Basis des AIE-Modells stattfindet.

Die Simulation des AIE-Modells erfordert einige Eingaben:

G : Durch das AIE-Modell wird die Zielauswahl in einer kognitiven Architektur simuliert. G ist die endliche Menge der zu simulierenden Aufgabenziele.

\circ : Zur Bestimmung der Aufmerksamkeitsgewichte kann die additive oder multiplikative Variante der Gleichung 3.1 verwendet werden. Mit \circ wird angegeben, welcher Operator verwendet werden soll.

U, V : Mit den freien Parametern U und V werden die anwendungsunabhängigen Gewichte für die Erwartungs- und Wertvariablen angegeben.

Bei Verwendung des Lowest Ordinal Algorithmus zur Operationalisierung des Aufgabenwertes $v(g)$ sind weitere Eingaben und Definitionen nötig:

S : Um den Lowest Ordinal Algorithmus als Heuristik zur Operationalisierung von $v(g)$ zu verwenden, müssen vor Beginn einer Simulation alle Situationen bestimmt werden, die simuliert werden sollen. S ist die endliche Menge dieser Situationen. Eine Situation wird durch die Belegung der unabhängigen Variablen definiert.

s : Mit s wird die aktuell simulierte Situation bezeichnet.

GS : Über den Lowest Ordinal Algorithmus wird $v(g)$ für jeweils alle Ziele in jeder Situation bestimmt. $GS = G \times S$ ist das kartesische Produkt aus den Aufgabenzielen G und den zu simulierenden Situationen S .

\leq : Der Lowest Ordinal Algorithmus wird als Heuristik verwendet, wenn eine direkte Quantifizierung von $v(g)$ schwierig ist, aber dennoch für viele Paare von Aufgabenziel-Situations-Tupeln $(g_1, s_1), (g_2, s_2) \in GS$ angegeben werden kann, ob der Wert des Aufgabenziels g_1 in der Situation s_1 größer oder kleiner ist als der Wert von g_2 in s_2 . Dies wird durch die auf GS definierte Halbordnung \leq angegeben. Es gilt $(g_1, s_1) \leq (g_2, s_2)$, wenn der Wert von g_1 in der Situation s_1 kleiner oder gleich dem Wert von g_2 in s_2 ist.

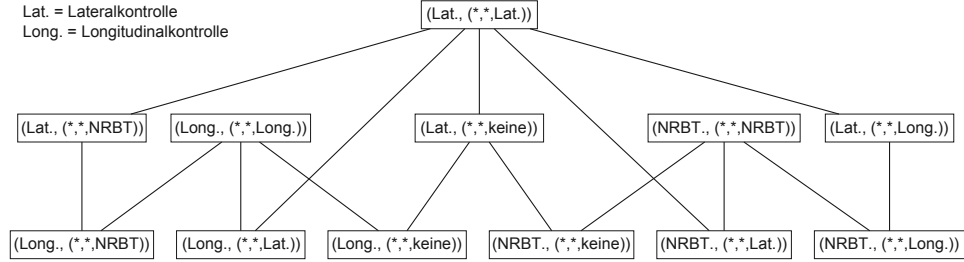


Abbildung A.1 – Hasse-Diagramm für die Ordnungsrelation \leq in der zweiten Evaluation (Fahrstudie). Abgebildet sind die Elemente aus GS .

DISTANCE : Die geordnete Menge (GS, \leq) lässt sich als Hasse-Diagramm darstellen. Die Funktion **DISTANCE** liefert für je zwei vergleichbare Elemente (g_1, s_1) und (g_2, s_2) aus GS die maximale Pfadlänge plus eins im Hasse-Diagramm. Das Hasse-Diagramm für die Fahrstudie der 2. Evaluation ist in **Abbildung A.1** dargestellt. Eine Situation in der Fahrstudie ist definiert durch ein 3-Tupel, das die Belegung der drei unabhängigen Variablen *Streckenschwierigkeit*, *NRBT-Frequenz* und *Aufgabenpriorität* angibt. Da weder die Streckenschwierigkeit noch die NRBT-Frequenz einen Einfluss auf den Wert $v(g)$ eines Aufgabenziels hat, wird die Ausprägung dieser Variablen in **Abbildung A.1** nicht betrachtet. So werden in **Abbildung A.1** mit $(*, *, g)$ alle Situationen bezeichnet, bei der das Aufgabenziel g priorisiert wurde.

Algorithmus 1 Funktion processGoalAgenda

Input:

$G \leftarrow$ finite set of task goals ▷ The goal agenda
 $\circ \in \{+, \cdot\}$
 $U, V \in \mathbb{R}^+$ ▷ weights for expectancy and value factors, free parameters

```

1: function PROCESSGOALAGENDA( $G, U, V, \circ$ )
2:   loop ▷ Infinite loop shown in statechart of Figure 3.3
3:     for all  $g \in G$  do ▷ Equation 3.1
4:        $w_g \leftarrow \left( U \cdot \frac{u(g)}{\sum_{g_i \in G} u(g_i)} \right) \circ \left( V \cdot \frac{v(g)}{\sum_{g_i \in G} v(g_i)} \right)$ 
5:     end for
6:     activeGoal  $\leftarrow$  select from  $G$  with probability  $P(g) = \frac{w_g}{\sum_{g_i \in G} w_{g_i}}$  ▷
7:     Equation 3.2
8:     PROCESSTASKGOAL(activeGoal)
9:   end loop
10: end function

```

Algorithmus 2 Operationalisierung v : Lowest Ordinal Algorithm

Input: $S \leftarrow$ finite set of simulated situations $s \leftarrow$ currently simulated situation $GS \leftarrow G \times S$
 \leq : Partial order for GS such that $(g_1, s_1) \leq (g_2, s_2)$, if value of g_1 in situation s_1 is less or
equal to the value of g_2 in s_2 .DISTANCE: $GS \times GS \rightarrow \mathbb{N}$ \triangleright ordinal distance according to \leq 1: **function** $v(g)$ 2: $GS_{pre} \leftarrow \{(g_i, s_j) \in GS \mid (g_i, s_j) \leq (g, s)\}$ \triangleright Set of predecessors of (g, s) 3: **return** $\max_{(g_i, s_j) \in GS_{pre}} (\text{DISTANCE}((g_i, s_j), (g, s)))$ 4: **end function**

In Abschnitt 3.3 wurden zwei Operationalisierungsvarianten für die Erwartungsvariablen $u(g)$ angegeben. Die erste Operationalisierungsvariante auf Basis der Ereignisrate ist in Algorithmus 3 abgebildet. Die zweite Variante auf Basis der Ereignisfunktionen ist in Algorithmus 4 abgebildet.

Algorithmus 3 Operationalisierung u , Variante 1: Ereignisrate

Input: E : Set of observed events1: **function** $u(g)$ 2: $d_g \leftarrow$ total time g was active3: $E_g \leftarrow \{(g_i, t) \in E \mid g_i = g\}$ 4: **return** $|E_g|/d_g$ \triangleright Equation 3.45: **end function**

Algorithmus 4 Operationalisierung u , Variante 2: Ereignisfunktion

Input: t : current simulation time E : Set of observed events1: **function** $u(g)$ 2: $d_g \leftarrow$ total time g was active3: $E_g \leftarrow \{(g_i, t) \in E \mid g_i = g\}$ 4: $DT_g = \{d \mid e_{g,i} \in E_g \wedge e_{g,i+1} \in E_g \wedge d = t_{i+1} - t_i\}$ \triangleright Event distances, Equation 3.75: H_g : cumulative frequency of real-valued random variable DT_g 6: $t_{g,prev} \leftarrow \max\{t^* \mid (g, t^*) \in E, t^* < t\}$ \triangleright Equation 3.97: **return** $H_g(t - t_{g,prev})/d_g$ \triangleright Equation 3.8 and 3.108: **end function**

Algorithmus 5 Funktion processTaskGoal

Input:*t*: current simulation time*E*: Set of observed events

```
1: function PROCESSTASKGOAL(g) ▷ Figure 3.4
2:   Look at information source relevant for g and obtain presented information
3:
4:   if perceived information requires reaction then
5:     add  $e = (g, t)$  to E ▷ Definition 4
6:     execute required action
7:
8:   end if
9: end function
```

Anhang B

Details zur Fahrstudie

B.1 Versuchspersonen

Versuchsperson	Alter (Jahre)	Geschlecht	Jährliche Kilometerzahl	Führerscheinbesitz (Jahre)	Simulatorkrankheit (s. Angaben zur Person: Aussage 1)	Simulatorlenkung (s. Angaben zur Person: Aussage 2)
1	29	w	8000	11	4	1
2	22	m	3000	4		
3	31	m	20000	13		
4	29	m	25000	11,5	5	2
5	31	m	2000	13	4	1
6	31	m	10000	12	5	2,5
7	54	m	35000	36		5
8	52	w	20000	34		
9	28	m	15000	10	4	1
10	28	w	2000	10	4	1
11	29	w	5000	11	2	1
12	26	m	15000	8		
13	33	w	3000	15		
14	42	w	18000	24		
15	30	m	7000	12	5	1
16	33	m	15000	15	5	1
17	33	m	0	15		
18	30	w	10000	12		3
19	29	w	30	11	4	3
20	30	w	20000	12	3	4
21	36	m	20000	18	5	3
\bar{M}	32.67	9 w/12 m	12049	14.64	4.17	2.11

Tabelle B.1 – Zusätzliche Angaben zu den Versuchspersonen

B.2 Versuchsbedingungen

In Tabelle B.2 sind die Reihenfolgen der neun Versuchsbedingungen für jede Versuchsperson aufgelistet. Sie wurden randomisiert zugeteilt. Die Einträge in der Tabelle sind kodiert durch "Ereignisrate der Spurhalteaufgabe - Ereignisrate der Nebenaufgabe - Aufgabenpriorität" mit folgenden Symbolen:

L	=	Niedrige Ereignisrate (Low)
M	=	Mittlere Ereignisrate (Medium)
H	=	Hohe Ereignisrate (High)
∅	=	Keine Priorisierungsvorgabe
Lat	=	Hohe Priorität der Lateralkontrolle
Long	=	Hohe Priorität der Longitudinalkontrolle
2 nd T	=	Hohe Priorität der Nebenaufgabe

Versuchs- person	Reihenfolge der Versuchsbedingungen								
	1. Versuchblock			2. Versuchblock			3. Versuchblock		
	1	2	3	4	5	6	7	8	9
1	L-H-∅	M-H-∅	H-H-∅	L-L-∅	M-L-∅	H-L-∅	M-L-Lat	M-L-Lon	M-L-2 nd T
2	H-H-∅	M-H-∅	L-H-∅	H-L-∅	M-L-∅	L-L-∅	M-L-2 nd T	M-L-Lat	M-L-Lon
3	M-L-∅	L-L-∅	H-L-∅	M-H-∅	L-H-∅	H-H-∅	H-L-Lon	H-L-Lat	H-L-2 nd T
4	L-L-∅	H-L-∅	M-L-∅	L-H-∅	H-H-∅	M-H-∅	H-L-Lat	H-L-2 nd T	H-L-Lon
5	H-L-∅	L-L-∅	M-L-∅	H-H-∅	L-H-∅	L-H-∅	M-L-Lon	M-L-Lat	M-L-2 nd T
6	M-H-∅	H-H-∅	L-H-∅	M-L-∅	H-L-∅	L-L-∅	M-L-2 nd T	M-L-Lon	M-L-Lat
7	L-L-∅	M-L-∅	H-L-∅	L-H-∅	M-H-∅	H-H-∅	H-L-2 nd T	H-L-Lat	H-L-Lon
8	H-L-∅	M-L-∅	L-L-∅	H-H-∅	M-H-∅	L-H-∅	H-L-Lon	H-L-2 nd T	H-L-Lat
9	L-L-∅	M-L-∅	H-L-∅	L-H-∅	M-H-∅	H-H-∅	H-L-2 nd T	H-L-Lat	H-L-Lon
10	M-L-∅	L-L-∅	H-L-∅	M-H-∅	L-H-∅	H-H-∅	M-L-Lat	M-L-2 nd T	M-L-Lon
11	H-H-∅	L-H-∅	M-H-∅	H-L-∅	L-L-∅	M-L-∅	M-L-Lon	M-L-2 nd T	M-L-Lat
12	L-H-∅	M-H-∅	H-H-∅	L-L-∅	M-L-∅	H-L-∅	H-L-Lon	H-L-Lat	H-L-2 nd T
13	M-H-∅	L-H-∅	H-H-∅	M-L-∅	L-L-∅	H-L-∅	M-L-Lon	M-L-Lat	M-L-2 nd T
14	M-L-∅	H-L-∅	L-L-∅	M-H-∅	H-H-∅	L-H-∅	M-L-Lat	M-L-Lon	M-L-2 nd T
15	L-H-∅	H-H-∅	M-H-∅	L-L-∅	H-L-∅	M-L-∅	H-L-Lat	H-L-Lon	H-L-2 nd T
16	H-L-∅	L-L-∅	M-L-∅	H-H-∅	L-H-∅	M-H-∅	H-L-Lat	H-L-Lon	H-L-2 nd T
17	M-H-∅	L-H-∅	H-H-∅	M-L-∅	L-L-∅	H-L-∅	H-L-2 nd T	H-L-Lon	H-L-Lat
18	L-L-∅	H-L-∅	M-L-∅	L-H-∅	H-H-∅	M-H-∅	M-L-Lon	M-L-2 nd T	M-L-Lat
19	M-H-∅	H-H-∅	L-H-∅	M-L-∅	H-L-∅	L-L-∅	H-L-Lat	H-L-2 nd T	H-L-Lon
20	H-L-∅	M-L-∅	L-L-∅	H-H-∅	M-H-∅	L-H-∅	M-L-2 nd T	M-L-Lon	M-L-Lat
21	H-L-∅	M-L-∅	L-L-∅	H-H-∅	M-H-∅	L-H-∅	M-L-2 nd T	M-L-Lon	M-L-Lat

Tabelle B.2 – Reihenfolge der Versuchsbedingungen.

B.3 Formulare

Im Folgenden finden sich Informationen und Formulare, die in dieser Form den Versuchspersonen vor Beginn des Versuchs ausgehändigt wurden. Dies sind:

- Einverständniserklärung zur Teilnahme am Experiment und der Verwendung der aufgezeichneten Daten,
- Angaben zur Person,
- Aufgabenbeschreibung.

Zudem ist das vom Versuchsleiter abzuarbeitende und auszufüllende Experimentprotokoll abgebildet.

Einverständniserklärung zur Teilnahme am Experiment

„AALateral“

Liebe Studienteilnehmer,

vielen Dank für die Bereitschaft, an dieser Studie teilzunehmen. Ziel und Inhalt der Studie wird im „**Merkblatt Experiment im Fahrsimulator**“ beschrieben. Aus rechtlichen Gründen ist es notwendig, dass Sie die Teilnahme an dem Experiment schriftlich bestätigen. Bitte lesen sie nachfolgende Erläuterungen gründlich durch und unterschreiben Sie diese Einverständniserklärung. Vielen Dank.

Während der Studie werden Daten über den Studienverlauf erhoben. Dazu gehören:

- digitale Daten des Blickerfassungssystems,
- Daten der automatischen Versuchssteuerung (z.B. Displayinformationen, Fahrzeuggeschwindigkeit, Lenkrad- und Pedalbewegungen usw.),
- Daten zur Ihrer Person (z.B. Alter, Geschlecht, Fahrerfahrung usw.) Sämtliche Daten werden Dritten nicht zugänglich gemacht.

Diese Daten sind nur für die Zeit der Studie mit Ihrer Person verknüpft. Die Analyse, Veröffentlichung und Archivierung der Daten erfolgt anonymisiert. Zusammenfassungen der Daten (gemittelt über die Teilnehmer) werden anonymisiert in Textform, beispielsweise in wissenschaftlichen Artikeln publiziert und fließen in die Fahrermodellierung am Institut OFFIS ein.

Sie können sich jederzeit und ohne Nennung von Gründen aus der Studie zurückziehen. Sollten Sie Fragen haben, beantworten wir sie gerne. Vielen Dank, dass Sie mit ihrer Zeit unsere Arbeit und damit die Forschung im Bereich der Fahrerassistenzsystementwicklung unterstützen!

- 1) Ich bin bereit an dieser Studie teilzunehmen
- 2) Mir wurde erklärt, dass:
 - a. während der Studie digitale Aufzeichnungen gemacht werden,
 - b. alle persönlichen Informationen unter das Bundesdatenschutzgesetz fallen, was bedeutet, dass meine Identität nicht ohne meine Einwilligung preisgegeben wird,
 - c. alle gesammelten Daten ausschließlich anonymisiert verwendet werden,
 - d. ich jederzeit und ohne Begründung eine Aktivität oder die gesamte Teilnahme an der Studie abbrechen kann.

3) Datenweitergabe:

- Ja, ich erlaube die Weitergabe meiner Daten in anonymisierter Form an Dritte (z.B. Forschungspartner von OFFIS oder Interessierte aus der wissenschaftlichen Community).
- Nein, bitte verwenden Sie meine Daten nur für die Arbeit am OFFIS.

4) Dürfen wir Sie anschreiben, um an weiteren Studien teilzunehmen?

- Ja Nein

Telefon, Email oder Anschrift: _____

Ich habe die Teilnahmeinformationen aufmerksam gelesen und bin damit einverstanden, dass meine Kontaktdaten für den Zeitraum der Studie gespeichert werden und die Ergebnisse der Studie anonymisiert im wissenschaftlichen Kontext veröffentlicht werden können.

Teilnehmer

Name _____ Vorname _____

Oldenburg, den _____ Unterschrift _____

VP Kennung

Studienkennung

Angabe zusätzlicher statistischer Daten zur Person

Alle Angaben sind freiwillig.

Alter: _____

Geschlecht: w m

Führerschein seit _____ Jahren

Geschätzte Kilometer pro Jahr: _____ km

Kontaktlinsen- oder Brillenträger: Ja Nein

Bitte bewerten Sie folgende Aussagen:

- 1) Die Lenkung des Fahrsimulators erlaubte es mir das Fahrzeug sicher zu führen.

1	2	3	4	5
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Trifft nicht zu				Trifft voll zu

- 2) Mir wurde übel im Fahrsimulator.

1	2	3	4	5
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Trifft nicht zu				Trifft voll zu

Aufgabenbeschreibung

Sie werden zuerst ein Trainingsszenario fahren, um sich mit dem Simulator und der Nebenaufgabe vertraut zu machen. Anschließend werden Sie drei Szenarien von jeweils etwa 15 Minuten Länge fahren. Am Ende jedes Szenarios erscheint ein Stoppschild an der Straße. Wir bitten Sie dort anzuhalten.

Ihre Aufgabe während der Fahrt besteht darin das Fahrzeug sicher auf der Fahrspur zu führen, während Sie eine Nebenaufgabe lösen. Wir bitten Sie dabei auf drei Aspekte besonders zu achten:

- Versuchen Sie das Fahrzeug immer möglichst mittig in der Spur zu halten.
- Versuchen Sie immer möglichst genau eine Geschwindigkeit von 100 km/h einzuhalten.
- Versuchen Sie immer möglichst schnell korrekt auf die Nebenaufgaben zu reagieren. Mit der Nebenaufgabe werden Sie gleich vertraut gemacht.

Bei der Interaktion mit der Nebenaufgabe beachten Sie bitte, dass Sie das Fahrzeug jederzeit sicher führen sollen.

B.4 Experimentprotokoll

Dem Versuchsleiter lag folgendes Experimentprotokoll des Versuchsablaufs vor.

Experimentprotokoll

Material

- Wasser und Gläser
- Einverständniserklärung
- Fragebogen zu personenbezogenen Angaben
- Versuchsbeschreibung
- Kamera

Vorbereitung

- Auswahl der Situationsreihenfolge und Eintragung in die Versuchspersonentabelle.
- Erstellen der Situationstabelle für die Versuchsperson.

Ablauf

1. Aushändigen der *Versuchsbeschreibung* und der *Einverständniserklärung zur Teilnahme am Experiment* an die Versuchsperson.
2. Die unterschriebene Einverständniserklärung einsammeln und den Fragebogen zu den personenbezogenen Daten von der Versuchsperson ausfüllen lassen.
3. *Sie werden heute in verschiedenen Szenarien mit kurvenreichen Strecken fahren. Insgesamt wird der gesamte Versuch etwa eine Stunde dauern. Während dieser Zeit werden Ihre Blickbewegungen von einem Eyetracker aufgezeichnet, der an einem Brillengestell befestigt ist.*

Es kann häufiger dazu kommen, dass Versuchspersonen während der Fahrt übel wird. Bitte geben Sie an sobald Sie ein Gefühl von Übelkeit empfinden. In diesem Fall wird der Versuch nicht weitergeführt.

Ihre Aufgabe besteht darin, das Fahrzeug sicher auf der Fahrspur zu führen, während Sie eine Nebenaufgabe lösen. Wir bitten Sie dabei auf drei Aspekte besonders zu achten:

- *Versuchen Sie das Fahrzeug immer möglichst mittig in der Spur zu halten.*
- *Versuchen Sie immer möglichst genau eine Geschwindigkeit von 100 km/h einzuhalten.*
- *Versuchen Sie immer möglichst schnell korrekt auf die Nebenaufgaben zu reagieren. Mit der Nebenaufgabe werden Sie gleich vertraut gemacht.*

Nach jeweils etwa 15 Minuten erscheint ein Stoppschild an der Straße. Wir bitten Sie dort anzuhalten. Sie erhalten dann eine kurze Ruhepause. Wir beginnen mit einer ca. 10 minütigen Trainingsstrecke.

Haben Sie bis hierhin noch Fragen?

4. Die Versuchsperson auf dem Fahrersitz Platz nehmen lassen und Sie auffordern den Sitz in eine Komfortposition zu bringen.
5. Einrichten des Eyetrackers.
 - (a) Jalousien schließen.
 - (b) Aufsetzen des Eyetrackers. Sicherstellen, dass er festen Halt hat.
 - (c) Dikablis Record starten und Projekt *AttentionAllocation* laden.
 - (d) Neues Experiment VP<VPID> anlegen.
 - (e) Wechselnde Kalibrierung des Eyetrackers auf die Bereiche: FrontView, Tachometer, NRBT-Display
 - (f) Sicherstellen, dass alle optischen Marker sichtbar sind.
6. Laden des Trainings szenarios.
 - (a) In `AttentionAllocation.inc` TrainingMap einkommentieren.
 - (b) In `NumberReadBackTask.inc` Minimum- und Maximumabstand von Aufgaben festsetzen auf [2000, 6000].
 - (c) In `NumberReadBackTask.inc` den Ausgabedateinamen für die Überprüfung der Antworten auf `VP<VP ID>_Training` setzen.
 - (d) Szenario in Silab laden und starten.
 - (e) Den NRBT in der Mittelkonsole maximieren und Fokus geben.
 - (f) Timer synchronisieren.
7. Einführung in die Nebenaufgabe (NRBT)

Es werden in unregelmäßigen Abständen Ziffernfolgen auf dem Display angezeigt. Sobald Sie eine neue Ziffernfolge sehen, betätigen Sie den Schalter am Lenkrad einmal. Sie hören einen kurzen Piepton zur Bestätigung. Die Ziffern bleiben eine kurze Zeit sichtbar. Lesen Sie sie bitte vor. Danach werden die Ziffern durch X'e ausgeblendet. Bitte probieren Sie dies aus.

Bei Betätigung des Schalters, wenn keine Zahlen zu sehen sind ertönt ein kurzer, dumpfer Piepton. Dies wird ebenso wie ein Fehler beim Vorlesen der Zahlen mit einer sehr hohen Reaktionszeit gewertet.
8. Eingewöhnung an den Simulator. Auf korrektes Lenkverhalten hinweisen.
9. Laden des ersten Szenarios.
 - (a) Die Versuchsperson zu Kontrollblicken für die Eyetrackerjustierung auffordern: (1) Fluchtpunkt (2) Zentrum des Tachometers (3) Zentrum der Nebenaufgabe
 - (b) In `AttentionAllocation.inc` die richtige Map einkommentieren.

- (c) In `NumberReadBackTask.inc` Minimum-und Maximumabstand von Aufgaben festsetzen.
 - (d) In `NumberReadBackTask.inc` Ausgabedateinamen setzen auf:
`VP<VP ID>_<Kurvenreihenfolge>_<Ziffernrate>_<Priorität>`.
 - (e) Szenario in Silab laden und starten.
 - (f) Den NRBT in der Mittelkonsole maximieren und Fokus geben.
 - (g) Timer synchronisieren.
10. *Es beginnt nun die erste Phase von 15 Minuten. Am Ende des Szenarios erscheint ein Stoppschild. Bitte halten Sie dort an.*
11. Laden des zweiten Szenarios (s. Schritt 9)
12. *Es beginnt nun die zweite Phase von 15 Minuten. Am Ende des Szenarios erscheint wieder ein Stoppschild. Bitte halten Sie dort an.*
13. Laden des letzten Szenarios.
- (a) Die Versuchsperson zu Kontrollblicken für die Eyetrackerjustierung auffordern: (1) Fluchtpunkt (5) Zentrum des Tachometers (6) Zentrum der Nebenaufgabe
 - (b) In `AttentionAllocation.inc` die richtige Map einkommentieren.
 - (c) In `NumberReadBackTask.inc` Minimum-und Maximumabstand von Aufgaben festsetzen.
 - (d) In `NumberReadBackTask.inc` Ausgabedateinamen setzen auf:
`VP<VP ID>_<MMM | HHH>_L_<Prioritätsreihenfolge>`.
 - (e) Szenario in Silab laden und starten.
 - (f) Den NRBT in der Mittelkonsole maximieren und Fokus geben.
 - (g) Timer synchronisieren.
14. *Es beginnt nun die letzte Phase von 15 Minuten. Sie ist unterteilt in Abschnitte von jeweils 5 Minuten. Am Ende jedes Abschnittes erscheint ein Stoppschild. Halten Sie dort bitte an.*
15. *Bitte priorisieren Sie in diesem Abschnitt die <1. Prioritätsaufgabe>: Sie können losfahren.*
16. *Bitte priorisieren Sie in diesem Abschnitt die <2. Prioritätsaufgabe>: Sie können losfahren.*
17. *Bitte priorisieren Sie in diesem Abschnitt die <3. Prioritätsaufgabe>: Sie können losfahren.*
18. Post-Fragebogen von der Versuchsperson ausfüllen lassen.

B.5 Ergebnisse der Anova

Es folgen die vollständigen Angaben zu den durchgeführten Anovas.

Tabelle B.3 – Ergebnisse der Varianzanalyse zur prozentualen Blickverteilung.

Quelle	<i>df</i>	Mean square	F	p
<u>Prozentuale Blickverweildauer zur Straße</u>				
<u>1. Versuchsteil</u>				
NRBT	1	0.0512	29.062 ***	<0.001
Res. NRBT	13	0.0017		
Strecke	2	0.1701	120.724 ***	<0.001
Res. Strecke	26	0.0014		
leicht ↔ mittel	26		t = 5.607 ***	<0.001
mittel ↔ schwer	26		t = 9.747 ***	<0.001
Strecke × NRBT	2	0.0003	0.391	0.680
Res. Strecke × NRBT	26	0.0007		
<u>2. Versuchsteil</u>				
Strecke	1	0.0529	4.855 *	0.048
Res. Strecke	12	0.0109		
Priorität	2	0.0930	61.202 ***	<0.001
Lateral↔Longitudinal	24		t = 5.878 ***	<0.001
Lateral↔NRBT	24		t = 4.952 ***	<0.001
NRBT↔Longitudinal	24		t = 0.926	0.364
Strecke × Priorität	2	0.0045	2.935 .	0.072
Res. Prio. × Strecke	24	0.0015		
<u>Prozentuale Blickverweildauer zur Nebenaufgabe</u>				
<u>1. Versuchsteil</u>				
NRBT	1	0.0686	17.838 **	0.001
Res. NRBT	13	0.0038		
Strecke	2	0.0405	87.480 ***	<0.001
Res. Strecke	26	0.0005		
leicht ↔ mittel	26		t = 8.829 ***	<0.001
mittel ↔ schwer	26		t = 4.115 ***	<0.001
Strecke × NRBT	2	0.0009	2.976 .	0.069
Res. Strecke × NRBT	26	0.0003		
<u>2. Versuchsteil</u>				
Strecke	1	0.0163	2.842	0.118
Res. Strecke	12	0.0057		
Priorität	2	0.0317	32.595 ***	<0.001
NRBT↔Longitudinal	24		t = 4.005 ***	<0.001
NRBT↔Lateral	24		t = 4.078 ***	<0.001
Lateral↔Longitudinal	24		t = 0.073	0.942
Strecke × Priorität	2	0.0011	1.112	0.345
Res. Prio. × Strecke	24	0.0010		

Wird fortgesetzt ...

... Fortsetzung von Tabelle B.3

Quelle	<i>df</i>	Mean square	F	p
<u>Prozentuale Blickverweildauer zur Tachoanzeige</u>				
<u>1. Versuchsteil</u>				
NRBT	1	0.0003	0.807	0.385
Res. NRBT	13	0.0004		
Strecke	2	0.0253	32.920 ***	<0.001
Res. Strecke	26	0.0008		
leicht ↔ mittel	26		t = 3.589 **	0.001
mittel ↔ schwer	26		t = 4.508 ***	<0.001
Strecke × NRBT	2	0.0002	1.021	0.374
Res. Strecke × NRBT	26	0.0002		
<u>2. Versuchsteil</u>				
Strecke	1	0.0090	1.234	0.288
Res. Strecke	12	0.0072		
Priorität	2	0.0775	48.180 ***	<0.001
Longitudinal ↔ Lateral	24		t = 5.072 ***	<0.001
Longitudinal ↔ NRBT	24		t = 3.840 ***	<0.001
Lateral ↔ NRBT	24		t = 1.232	0.230
Strecke × Priorität	2	0.0049	3.042 .	0.066
Res. Prio. × Strecke	24	0.0016		

Tabelle B.4 – Ergebnisse der Varianzanalyse zu den Blickfrequenzen.

Quelle	<i>df</i>	Mean square	F	p
<u>Blickfrequenz zur Straße</u>				
<u>1. Versuchsteil</u>				
NRBT	1	0.0181	5.261 *	0.039
Res. NRBT	13	0.0034		
Strecke	2	0.0498	11.488 ***	<0.001
Res. Strecke	26	0.0043		
leicht ↔ mittel	26		t = 0.101	0.921
mittel ↔ schwer	26		t = 4.100 ***	<0.001
Strecke × NRBT	2	0.0024	1.763	0.192
Res. Strecke × NRBT	26	0.0014		
<u>2. Versuchsteil</u>				
Strecke	1	0.0001	0.002	0.962
Res. Strecke	12	0.0413		
Priorität	2	0.1028	30.465 ***	<0.001
Lateral ↔ Longitudinal	24		t = 5.201 ***	<0.001
Lateral ↔ NRBT	24		t = 3.209 **	0.004
Longitudinal ↔ NRBT	24		t = 1.992 .	0.058
Strecke × Priorität	2	0.0005	0.146	0.865
Res. Prio. × Strecke	24	0.0034		

Wird fortgesetzt ...

... Fortsetzung von Tabelle B.4

Quelle	<i>df</i>	Mean square	F	p
<u>Blickfrequenz zur Nebenaufgabe</u>				
<u>1. Versuchsteil</u>				
NRBT	1	0.0421	7.061 *	0.020
Res. NRBT	13	0.0060		
Strecke	2	0.0210	12.037 ***	<0.001
Res. Strecke	26	0.0017		
leicht ↔ mittel	26		t = 0.164	0.871
mittel ↔ schwer	26		t = 4.165 ***	<0.001
Strecke × NRBT	2	0.0020	1.652	0.211
Res. Strecke × NRBT	26	0.0012		
<u>2. Versuchsteil</u>				
Strecke	1	0.0147	0.297	0.596
Res. Strecke	12	0.0496		
Priorität	2	0.0624	27.257 ***	<0.001
NRBT ↔ Lateral	24		t = 3.605 **	0.001
NRBT ↔ Longitudinal	24		t = 3.578 **	0.002
Lateral ↔ Longitudinal	24		t = 0.028	0.978
Strecke × Priorität	2	0.0026	1.158	0.331
Res. Prio. × Strecke	24	0.0023		
<u>Blickfrequenz zur Tachoanzeige</u>				
<u>1. Versuchsteil</u>				
NRBT	1	0.0145	4.691 *	0.049
Res. NRBT	13	0.0031		
Strecke	2	0.0330	13.099 ***	<0.001
Res. Strecke	26	0.0025		
leicht ↔ mittel	26		t = 1.713 .	0.099
mittel ↔ schwer	26		t = 3.321 **	0.003
Strecke × NRBT	2	0.0000	0.002	0.998
Res. Strecke × NRBT	26	0.0014		
<u>2. Versuchsteil</u>				
Strecke	1	0.0040	0.242	0.631
Res. Strecke	12	0.0166		
Priorität	2	0.2251	60.474 ***	<0.001
Longitudinal ↔ Lateral	24		t = 6.301 ***	<0.001
Longitudinal ↔ NRBT	24		t = 5.044 ***	<0.001
NRBT ↔ Lateral	24		t = 1.256	0.221
Strecke × Priorität	2	0.0056	1.498	0.244
Res. Prio. × Strecke	24	0.0037		

Tabelle B.5 – Ergebnisse der Varianzanalyse zur Geschwindigkeit.

Quelle	<i>df</i>	Mean square	F	p
<u>1. Versuchsteil</u>				
NRBT	1	0.169	0.113	0.741
Res. NRBT	16	1.500		
Strecke	2	56.969	16.813 ***	<0.001
Res. Strecke	32	3.388		
leicht ↔ mittel	32		t = 0.230	0.820
mittel ↔ schwer	32		t = 5.133 ***	<0.001
Strecke × NRBT	2	0.598	0.994	0.381
Res. Strecke × NRBT	32	0.602		
<u>2. Versuchsteil</u>				
Strecke	1	11.944	2.607	0.127
Res. Strecke	15	4.581		
Priorität	2	2.197	1.158	0.328
Strecke × Priorität	2	3.329	1.754	0.190
Res. Prio. × Strecke	30	1.898		

Tabelle B.6 – Ergebnisse der Varianzanalyse zur Abweichung von der Zielgeschwindigkeit.

Quelle	<i>df</i>	Mean square	F	p
<u>1. Versuchsteil</u>				
NRBT	1	1.018	0.884	0.361
Res. NRBT	16	1.151		
Strecke	2	22.287	13.072 ***	<0.001
Res. Strecke	32	1.705		
leicht ↔ mittel	32		t = 1.158	0.255
mittel ↔ schwer	32		t = 3.734 ***	<0.001
Strecke × NRBT	2	0.577	1.243	0.302
Res. Strecke × NRBT	32	0.465		
<u>2. Versuchsteil</u>				
Strecke	1	1.833	0.620	0.443
Res. Strecke	15	2.955		
Priorität	2	11.666	17.085 ***	<0.001
Lateral ↔ Longitudinal	30		t = 3.008 **	0.005
Lateral ↔ NRBT	30		t = 0.314	0.756
Longitudinal ↔ NRBT	30		t = 3.322 **	0.002
Strecke × Priorität	2	0.149	0.218	0.805
Res. Prio. × Strecke	30	0.683		

Tabelle B.7 – Ergebnisse der Varianzanalyse zur mittleren Spurposition.

Quelle	<i>df</i>	Mean square	F	p
<u>1. Versuchsteil</u>				
NRBT	1	0.0013	1.402	0.254
Res. NRBT	16	0.0009		
Strecke	2	0.2799	95.803 ***	<0.001
Res. Strecke	32	0.0029		
leicht ↔ mittel	32		t = 3.869 ***	<0.001
mittel ↔ schwer	32		t = 9.576 ***	<0.001
Strecke × NRBT	2	0.0001	0.190	0.828
Res. Strecke × NRBT	32	0.0004		
<u>2. Versuchsteil</u>				
Strecke	1	0.1347	13.329 **	0.002
Res. Strecke	15	0.0101		
Priorität	2	0.0079	9.555 ***	<0.001
Lateral ↔ Longitudinal	30		t = 2.154 *	0.039
Lateral ↔ NRBT	30		t = 2.490 *	0.019
Longitudinal ↔ NRBT	30		t = 0.335	0.740
Strecke × Priorität	2	0.0001	0.135	0.874
Res. Prio. × Strecke	30	0.0008		

Tabelle B.8 – Ergebnisse der Varianzanalyse zu Fehlern bei den NRBT-Antworten.

Quelle	<i>df</i>	Mean square	F	p
<u>1. Versuchsteil</u>				
NRBT	1	12.706	4.884 *	0.042
Res. NRBT	16	2.602		
Strecke	2	2.422	0.991	0.382
Res. Strecke	32	2.442		
Strecke × NRBT	2	0.618	0.967	0.391
Res. Strecke × NRBT	32	0.638		
<u>2. Versuchsteil</u>				
Strecke	1	0.353	0.159	0.696
Res. Strecke	15	2.222		
Priorität	2	0.706	0.997	0.381
Strecke × Priorität	2	0.002	0.003	0.997
Res. Prio. × Strecke	30	0.708		

Tabelle B.9 – Ergebnisse der Varianzanalyse zu den NRBT-Reaktionszeiten.

Quelle	<i>df</i>	Mean square	F	p
<u>1. Versuchsteil</u>				
NRBT	1	674	0.712	0.411
Res. NRBT	16	947		
Strecke	2	9516	13.509 ***	<0.001
Res. Strecke	32	704		
leicht ↔ mittel	32		t = 0.313	0.756
mittel ↔ schwer	32		t = 4.337 ***	<0.001
Strecke × NRBT	2	132	0.464	0.633
Res. Strecke × NRBT	32	285		
<u>2. Versuchsteil</u>				
Strecke	1	1192	0.368	0.553
Res. Strecke	15	3238		
Priorität	2	3187	58.875 ***	<0.001
Lateral ↔ Longitudinal	30		t = 0.822	0.417
Lateral ↔ NRBT	30		t = 6.670 ***	<0.001
NRBT ↔ Longitudinal	30		t = 5.848 ***	<0.001
Strecke × Priorität	2	14	0.259	0.774
Res. Prio. × Strecke	30	54		

Anhang C

Datenbasen

In diesem Kapitel finden sich die Datenbasen zu einer Vielzahl von Abbildungen, in denen Ergebnisse aus Versuchs- oder Simulationsreihen dargestellt sind. Untersuchungsergebnisse, die in der textuellen Ausarbeitung nur für einzelne Modellvarianten beschrieben sind, werden hier der Vollständigkeit halber für alle Modellvarianten aufgelistet. Für eine kompakte Darstellung werden folgende Abkürzungen und Symbole bei der Beschriftung der Tabellen verwendet:

VP	=	Experimentergebnisse der Versuchspersonen. Für Senders Aufgabe sind die Daten aus (Senders, 1983) entnommen.
-AIE	=	Simulationsergebnisse mit deaktiviertem AIE-Modell
SE ⁺	=	Simulationsergebnisse mit additiver SEEV-Formulierung und statischen Erwartungsparametern
SE [*]	=	Simulationsergebnisse mit multiplikativer SEEV-Formulierung und statischen Erwartungsparametern
S-AIE ⁺	=	Simulationsergebnisse mit additiver SEEV-Formulierung und dynamischer Operationalisierung der Erwartungsparameter über die Ereignisrate
AIE ⁺	=	Simulationsergebnisse mit additiver SEEV-Formulierung und dynamischer Operationalisierung der Erwartungsparameter über Ereignisfunktionen
AIE [*]	=	Simulationsergebnisse mit multiplikativer SEEV-Formulierung und dynamischer Operationalisierung der Erwartungsparameter über Ereignisfunktionen
Lat	=	Lateralkontrolle
Long	=	Longitudinalkontrolle
R ²	=	Bestimmtheitsmaß
RMSD	=	Wurzel der mittleren quadratischen Abweichung (Root Mean Square Deviation)
r	=	Korrelationskoeffizient nach Pearson
V _K	=	Differenzmaß aus Kuiper's Test
f _{Gaze}	=	Blickfrequenz
Δt _{Gaze}	=	Blickdauer
RT	=	NRBT Reaktionszeit
ΔLat	=	Durchschnittliche Abweichung von der mittleren Spurposition
\bar{v}	=	Durchschnittsgeschwindigkeit
$\overline{\Delta v}_{100}$	=	Mittlere Abweichung von 100 km/h

C.1 Senders Monitoring-Aufgabe

Tabelle C.1 – Durchschnittliche Blickfrequenzen aus Senders' Experimenten (Senders, 1983).

		Anzeigeeinstrument					
		1	2	3	4	5	6
Experiment	1	0.256	0.532	0.666	1.662		
	2	0.215	0.236	0.284	0.353	0.435	0.494
	3	0.180	0.239	0.278	0.344	0.478	0.572
	4	0.160	0.162	0.221	0.301	0.348	0.397
	5	0.199	0.238	0.223	0.278	0.411	0.475

Tabelle C.2 – Datenbasis zu Abbildungen 4.4, 4.5, 4.7 und 4.10, sowie Abschnitt 4.3.2.1

Experiment	Instrument	Blickfrequenz (Hz.)					
		VP	AIE ⁺ Abb. 4.5	AIE* Abb. 4.7	¬AIE Abb. 4.4	SE ⁺ Abb. 4.10	SE*
1	1	0.256	0.391	0.254	0.530	0.366	0.187
	2	0.532	0.441	0.383	0.531	0.422	0.348
	3	0.666	0.520	0.483	0.532	0.525	0.590
	4	1.662	0.588	0.521	0.533	0.649	0.755
	Gesamt	3.116	1.940	1.641	2.126	1.962	1.881
	R^2		0.851	0.657	0.856	0.907	0.806
	RMSD		1.096	1.172	1.170	1.035	0.931
2	1	0.215	0.223	0.072	0.353	0.219	0.067
	2	0.236	0.245	0.115	0.353	0.235	0.107
	3	0.284	0.295	0.281	0.354	0.287	0.244
	4	0.353	0.357	0.346	0.354	0.344	0.369
	5	0.435	0.417	0.461	0.355	0.427	0.529
	6	0.494	0.468	0.492	0.356	0.510	0.654
	Gesamt	2.017	2.005	1.767	2.125	2.023	1.970
R^2		0.996	0.939	0.989	0.994	0.997	
RMSD		0.036	0.189	0.251	0.020	0.274	
3	1	0.180	0.222	0.062	0.353	0.211	0.046
	2	0.239	0.230	0.106	0.354	0.229	0.089
	3	0.278	0.266	0.198	0.354	0.262	0.172
	4	0.344	0.340	0.358	0.354	0.321	0.325
	5	0.478	0.440	0.463	0.355	0.421	0.551
	6	0.572	0.499	0.516	0.356	0.568	0.730
	Gesamt	2.091	1.997	1.703	2.126	2.011	1.913
R^2		0.984	0.941	0.998	0.971	0.993	
RMSD		0.090	0.234	0.331	0.068	0.288	

Tabelle C.3 – Datenbasis zu Abbildung 4.6

	Transition						R^2	RMSD
	$p_{1,2}$	$p_{1,3}$	$p_{2,3}$	$p_{1,4}$	$p_{2,4}$	$p_{3,4}$		
VP	0.040	0.051	0.112	0.133	0.297	0.324		
-AIE	0.250	0.000	0.250	0.249	0.000	0.251	0.01	0.170
AIE ⁺	0.103	0.132	0.159	0.166	0.194	0.246	0.87	0.071
AIE [*]	0.090	0.102	0.172	0.116	0.204	0.315	0.81	0.051

Tabelle C.4 – Datenbasis zu Abbildung 4.8 und 4.9 (inklusive Experiment 1 und 3)

Exper.	U V		Blickfrequenz pro Anzeiginstrument [Hz.]						R^2	RMSD
			1	2	3	4	5	6		
1	1	0	0.231	0.400	0.481	0.524			0.630	1.161
	2	1	0.173	0.212	0.282	0.333			0.778	1.094
	1	1	0.191	0.220	0.270	0.320			0.850	1.096
	1	2	0.425	0.463	0.514	0.566			0.869	1.121
	0	1	0.494	0.497	0.495	0.498			0.669	1.200
		VP	0.256	0.532	0.666	1.662				
	2	1	0	0.066	0.119	0.272	0.346	0.458	0.498	0,948
5		1	0.138	0.154	0.290	0.384	0.435	0.499	0,946	0.117
4		1	0.154	0.176	0.280	0.376	0.442	0.496	0,971	0.061
3		1	0.158	0.186	0.283	0.380	0.436	0.499	0,970	0.081
2		1	0.180	0.203	0.280	0.367	0.443	0.493	0,988	0.051
3		2	0.196	0.217	0.292	0.361	0.440	0.479	0,987	0.034
4		3	0.206	0.219	0.289	0.365	0.440	0.472	0,985	0.033
5		4	0.208	0.232	0.298	0.353	0.425	0.478	0,994	0.024
1		1	0.223	0.245	0.295	0.357	0.417	0.468	0,996	0.036
4		5	0.238	0.251	0.305	0.363	0.409	0.451	0,989	0.061
3		4	0.240	0.259	0.300	0.354	0.410	0.452	0,998	0.090
2		3	0.246	0.263	0.307	0.348	0.399	0.455	0,995	0.070
1		2	0.266	0.279	0.314	0.345	0.387	0.435	0,994	0.105
1		3	0.288	0.290	0.320	0.344	0.380	0.409	0,995	0.140
1		4	0.296	0.300	0.319	0.342	0.376	0.401	0,997	0.156
1		5	0.301	0.311	0.325	0.342	0.365	0.395	0,986	0.172
0	1	0.338	0.340	0.336	0.341	0.341	0.343	0,517	0.245	
	VP	0.215	0.236	0.284	0.353	0.435	0.494			
3	1	0	0.068	0.101	0.197	0.316	0.478	0.512	0.959	0.206
	2	1	0.179	0.205	0.248	0.337	0.453	0.528	0.990	0.067
	1	1	0.222	0.230	0.266	0.340	0.440	0.499	0.984	0.092
	1	2	0.262	0.268	0.295	0.343	0.393	0.462	0.982	0.163
	0	1	0.340	0.340	0.339	0.342	0.341	0.336	0.254	0.336
		VP	0.180	0.239	0.278	0.344	0.474	0.572		

Tabelle C.5 – Datenbasis zu Abbildung 4.11 und 4.12, sowie entsprechende Ergebnisse für das erste und dritte Experiment. Angegeben sind die geschätzten Funktionsparameter (a, b und c) für die angenommene Lernkurve $f(x) = a \cdot x^{-b} + c$

Experi- ment	Instru- ment	Abb. 4.12						Abb. 4.11	
		Blickfrequenz		Blickdauer		PDT		V_K	
		a	c	a	c	a	c	a	
AIE ⁺ -Agent	1	1	-0.060	0.387	-2.313	392	-0.033	0.189	0.137
		2	-0.013	0.443	5.351	401	-0.004	0.221	0.211
		3	0.020	0.521	13.20	418	0.018	0.270	0.373
		4	0.011	0.587	18.88	438	0.019	0.319	0.489
	b	1.010		0.571		1.029		0.465	
	2	1	-0.082	0.216	-5.759	379	-0.042	0.103	0.060
		2	-0.072	0.233	-5.627	380	-0.037	0.111	0.090
		3	-0.035	0.292	-2.089	386	-0.018	0.142	0.204
		4	0.006	0.354	7.750	396	0.005	0.175	0.302
		5	0.058	0.429	17.58	409	0.037	0.220	0.443
6		0.081	0.475	25.02	420	0.054	0.249	0.552	
b	0.682		0.463		0.674		0.440		
3	1	-0.089	0.213	-4.541	379	-0.045	0.101	0.038	
	2	-0.092	0.227	-5.766	379	-0.047	0.108	0.071	
	3	-0.038	0.269	-1.857	384	-0.020	0.129	0.126	
	4	0.004	0.338	6.108	393	0.003	0.166	0.215	
	5	0.050	0.435	18.30	411	0.033	0.224	0.346	
	6	0.107	0.507	35.16	429	0.073	0.270	0.471	
	b	0.750		0.479		0.731		0.415	
AIE [*] -Agent	1	1	-0.214	0.173	60.82	437	-0.106	0.096	0.076
		2	-0.093	0.360	123.8	507	-0.017	0.201	0.191
		3	-0.042	0.475	223.0	621	0.059	0.300	0.296
		4	-0.129	0.494	351.1	811	0.066	0.401	0.387
		b	0.413		0.176		0.636		0.347
	2	1	-0.327	0.000	-22.95	360	-0.157	0.001	0.024
		2	-0.292	0.061	-8.227	375	-0.143	0.029	0.056
		3	-0.069	0.252	73.15	451	-0.275	0.126	0.153
		4	0.062	0.373	157.7	534	0.056	0.200	0.311
		5	0.100	0.470	288.9	674	0.119	0.288	0.491
6		0.057	0.498	447.3	843	0.152	0.353	0.554	
b	0.432		0.109		0.450		0.359		
3	1	-0.373	-0.003	-34.35	349	-0.178	-0.002	0.018	
	2	-0.320	0.045	-17.83	364	-0.157	0.020	0.043	
	3	-0.163	0.166	55.42	434	-0.081	0.079	0.128	
	4	0.030	0.365	238.9	617	0.039	0.195	0.336	
	5	0.129	0.484	549.0	921	0.148	0.300	0.510	
	6	0.070	0.514	941.2	1340	0.208	0.402	0.763	
	b	0.502		0.067		0.515		0.417	

Tabelle C.6 – Datenbasis zu Abschnitt 4.3.5. Standardabweichungen der Blickfrequenzen aus den Experimenten 2, 4 und 5, sowie die zugehörigen Standardabweichungen des AIE-Modells.

Experi- ment	Anzeigeeinstrument						Mean	r ¹
	1	2	3	4	5	6		
2	0.011	0.037	0.044	0.044	0.017	0.056	0.035	
4	0.088	0.079	0.102	0.082	0.046	0.070	0.078	
5	0.076	0.067	0.074	0.124	0.031	0.081	0.076	
Mean ²	0.066	0.065	0.078	0.090	0.033	0.071	0.067	0.12
AIE ⁺	0.017	0.020	0.032	0.029	0.028	0.024	0.025	-0.69

¹ es wurde der Korrelationskoeffizient zwischen der Signalbandbreite der Instrumente und der Standardabweichung berechnet.

² Die Mittelwerte wurden gewichtet nach der Anzahl ausgewerteter Versuchspersonen berechnet

C.2 Fahrsimulatorstudie

Tabelle C.7 – Durchschnittswerte zu Kenngrößen des Blickverhaltens und der Aufgabenbearbeitung in Abhängigkeit von jeweils einer unabhängigen Variable. Abbildungen 5.6 bis 5.12 und 5.22, 5.25, 5.26, 5.28, 5.30, 5.33.

	Informations- quelle	Schwierigkeit				Aufgaben- ¹ priorisierung					
		der Lateralkontrolle			der NRBT		Keine	Long	Lat	NRBT	
		leicht	mittel	schwer	leicht	schwer					
Prozentuale Blickverweilzeiten (Abb. 5.6, 5.8, 5.25 und 5.33)											
Versuchspersonen	Straße	0.541	0.597	0.695	0.636	0.586	0.672	0.550	0.708	0.593	
	Tacho	0.144	0.118	0.084	0.117	0.113	0.101	0.223	0.085	0.106	
	NRBT	0.236	0.212	0.161	0.174	0.231	0.159	0.158	0.154	0.238	
	Mittlere Blickfrequenz in Hz. (Abb. 5.7, 5.8, 5.26 und 5.33)										
	Straße	0.552	0.550	0.478	0.512	0.542	0.495	0.657	0.489	0.600	
	Tacho	0.273	0.250	0.206	0.256	0.230	0.241	0.429	0.197	0.226	
	NRBT	0.364	0.363	0.316	0.325	0.370	0.312	0.324	0.321	0.438	
	Mittlere Blickdauern in ms (Abb. 5.28 und 5.33)										
	Straße	979	1076	1549	1301	1101	1201	837	1439	977	
	Tacho	530	481	410	464	483	474	507	409	456	
NRBT	629	558	493	510	610	560	505	483	546		
NRBT-Reaktionszeit in ms (RT) und Fehleranzahl (Abb. 5.11, 5.12(b) und 5.30)											
RT	1831	1901	2768	2249	2084	2426	2011	2178	1355		
Fehler	1.206	1.000	0.676	0.608	1.314	0.735	0.706	0.706	0.353		
Fahrverhalten ² (Abb. 5.9, 5.10, 5.12 und 5.30)											
Δ Lat	0.158	0.209	0.335	0.230	0.238	0.268	0.240	0.208	0.249		
\bar{v}	100.9	101.0	98.7	100.2	100.3	99.8	99.9	100.1	100.6		
Δv_{100}	1.708	2.075	3.257	2.246	2.446	2.530	1.295	2.565	2.852		
Prozentuale Blickverweilzeiten (Abb. 5.22)											
-AIE-Fahrermodell	Straße	0.503	0.517	0.555	0.537	0.519	0.536	0.538	0.531	0.528	
	Tacho	0.144	0.142	0.112	0.132	0.133	0.128	0.128	0.131	0.130	
	NRBT	0.233	0.238	0.247	0.230	0.250	0.242	0.234	0.234	0.236	
	Mittlere Blickfrequenz in Hz. (Abb. 5.22)										
	Straße	0.358	0.368	0.366	0.375	0.354	0.367	0.373	0.380	0.382	
	Tacho	0.350	0.344	0.276	0.324	0.322	0.310	0.311	0.323	0.317	
	NRBT	0.357	0.365	0.367	0.372	0.353	0.366	0.376	0.378	0.382	
	Mittlere Blickdauern in ms (Abb. 5.22)										
	Straße	1423	1456	1579	1482	1513	1517	1488	1444	1427	
	Tacho	444	444	439	440	445	442	441	440	443	
NRBT	676	674	692	635	727	683	636	637	636		
NRBT-Reaktionszeit in ms (RT)											
RT	2281	2224	2436	2272	2343	2330	2335	2220	2348		
Fahrverhalten ²											
Δ Lat	0.425	0.424	0.556	0.443	0.494	480	0.441	0.437	0.444		
\bar{v}	98.9	98.9	96.2	98.1	97.9	97.6	97.83	97.9	97.1		
Δv_{100}	1.323	1.171	3.841	1.985	2.238	2.51	2.12	2.21	2.94		

Wird fortgesetzt ...

... Fortsetzung von Tabelle C.7

	Informa- tions- quelle	Schwierigkeit				Aufgaben- ¹ priorisierung					
		der Lateralkontrolle			der NRBT		Keine	Long	Lat	NRBT	
		leicht	mittel	schwer	leicht	schwer					
Prozentuale Blickverweilzeiten (Abb. 5.25)											
AIE ⁺ -Fahrermodell	Straße	0.563	0.563	0.617	0.588	0.578	0.590	0.596	0.617	0.592	
	Tacho	0.112	0.114	0.108	0.118	0.105	0.111	0.145	0.108	0.090	
	NRBT	0.236	0.230	0.181	0.188	0.217	0.206	0.155	0.176	0.215	
	Mittlere Blickfrequenz in Hz. (Abb. 5.26)										
	Straße	0.526	0.515	0.451	0.511	0.494	0.483	0.502	0.483	0.495	
	Tacho	0.252	0.256	0.235	0.265	0.235	0.245	0.324	0.244	0.203	
	NRBT	0.349	0.331	0.272	0.313	0.329	0.301	0.247	0.290	0.360	
	Mittlere Blickdauern in ms (Abb. 5.28)										
	Straße	1101	1141	1400	1115	1153	1270	1235	1316	1225	
	Tacho	454	454	458	453	454	456	463	455	453	
NRBT	641	637	680	610	686	659	648	624	607		
NRBT-Reaktionszeit in ms (RT) (Abb. 5.30)											
RT	2058	2084	2217	2159	2080	2151	2374	2159	2018		
Fahrverhalten ² (Abb. 5.30)											
Δ Lat	0.171	0.197	0.334	0.216	0.252	0.266	0.257	0.229	0.267		
\bar{v}	99.4	99.4	98.3	99.1	98.9	98.9	99.0	99.1	98.9		
$\overline{\Delta v}_{100}$	1.178	1.101	2.384	1.433	1.676	1.743	1.472	1.988	1.011		
Prozentuale Blickverweilzeiten (Abb. 5.33)											
Straße	0.696	0.715	0.778	0.753	0.707	0.771	0.765	0.797	0.760		
Tacho	0.066	0.064	0.043	0.067	0.048	0.063	0.073	0.049	0.046		
NRBT	0.165	0.153	0.129	0.119	0.178	0.110	0.105	0.105	0.137		
Mittlere Blickfrequenz in Hz. (Abb. 5.33)											
Straße	0.365	0.339	0.248	0.303	0.332	0.277	0.289	0.236	0.288		
Tacho	0.149	0.144	0.097	0.152	0.109	0.141	0.164	0.110	0.103		
NRBT	0.230	0.206	0.158	0.160	0.235	0.144	0.133	0.132	0.194		
Mittlere Blickdauern in ms (Abb. 5.33)											
Straße	1955	2164	3339	2713	2258	3029	3001	3720	2829		
Tacho	448	450	445	447	448	446	445	447	447		
NRBT	724	752	821	762	769	788	807	810	715		
NRBT-Reaktionszeit in ms (RT)											
RT	1597	1717	2186	1893	1775	2035	2237	2198	1617		
Fahrverhalten ²											
Δ Lat	0.054	0.106	0.265	0.134	0.149	0.177	0.177	0.173	0.186		
\bar{v}	99.7	99.5	98.6	99.3	99.3	99.1	99.1	99.1	99.1		
$\overline{\Delta v}_{100}$	1.404	1.561	2.258	1.577	1.905	1.716	1.402	1.908	1.865		

Wird fortgesetzt ...

¹ *Keine* bezieht sich auf die durchschnittlichen Werte der mittleren und schweren Streckenbedingung bei niedriger NRBT-Rate aus den ersten beiden Versuchsblöcken, da der dritte Versuchsblock für die Ereignisraten lediglich diese Faktorstufen beinhaltet. *Long*, *Lat* und *NRBT* beziehen sich auf die Priorisierung im dritten Versuchsblock.

² Einheiten: Δ Lat in m, \bar{v} in km/h, $\overline{\Delta v}_{100}$ in km/h.

... Fortsetzung von Tabelle C.7

	Informations- quelle	Schwierigkeit				Aufgaben- ¹ priorisierung				
		der Lateralkontrolle			der NRBT		Keine	Long	Lat	NRBT
		leicht	mittel	schwer	leicht	schwer				
		Prozentuale Blickverweilzeiten								
	Straße	0.483	0.507	0.562	0.528	0.507	0.545	0.541	0.551	0.535
	Tacho	0.161	0.148	0.107	0.150	0.127	0.138	0.149	0.138	0.130
	NRBT	0.253	0.240	0.236	0.217	0.269	0.213	0.206	0.208	0.232
		Mittlere Blickfrequenz in Hz.								
SE ⁺ -Fahrmodell	Straße	0.386	0.429	0.414	0.433	0.386	0.446	0.442	0.451	0.430
	Tacho	0.324	0.306	0.227	0.311	0.260	0.291	0.309	0.289	0.273
	NRBT	0.362	0.354	0.329	0.340	0.357	0.333	0.322	0.327	0.359
		Mittlere Blickdauern in ms								
	Straße	1301	1224	1390	1259	1351	1262	1265	1259	1280
	Tacho	514	499	482	496	500	456	463	455	453
	NRBT	719	696	731	658	773	489	495	488	488
		NRBT-Reaktionszeit in ms (RT)								
	RT	2311	2314	2468	2472	2257	2492	2574	2550	2361
		Fahrverhalten ²								
	Δ Lat	0.427	0.366	0.426	0.377	0.436	0.366	0.371	0.355	0.388
	\bar{v}	98.9	99.0	97.0	98.5	98.1	98.2	98.2	98.3	98.1
	$\overline{\Delta v}_{100}$	1.612	1.503	3.107	1.836	2.312	2.034	2.079	2.023	2.221

¹ *Keine* bezieht sich auf die durchschnittlichen Werte der mittleren und schweren Streckenbedingung bei niedriger NRBT-Rate aus den ersten beiden Versuchsblöcken, da der dritte Versuchsblock für die Ereignisraten lediglich diese Faktorstufen beinhaltet. *Long*, *Lat* und *NRBT* beziehen sich auf die Priorisierung im dritten Versuchsblock.

² Einheiten: Δ Lat in m, \bar{v} in km/h, $\overline{\Delta v}_{100}$ in km/h.

Tabelle C.8 – Transitionswahrscheinlichkeiten der Versuchspersonen und Fahrermodelle. Abbildungen 5.23, 5.27 und 5.35.

Versuchs- ¹ bedingung	Transitionswahrscheinlichkeiten ²						R ²	RMSD
	$p_{S \rightarrow N}$	$p_{S \rightarrow T}$	$p_{N \rightarrow S}$	$p_{N \rightarrow T}$	$p_{T \rightarrow S}$	$p_{T \rightarrow N}$		
Versuchspersonen (Abb. 5.23, 5.27 und 5.35)								
L - L - \emptyset	0.232	0.230	0.288	0.010	0.176	0.066		
L - H - \emptyset	0.258	0.208	0.312	0.007	0.155	0.061		
M - L - \emptyset	0.255	0.216	0.293	0.010	0.178	0.048		
M - H - \emptyset	0.281	0.192	0.320	0.007	0.153	0.047		
H - L - \emptyset	0.261	0.210	0.296	0.011	0.176	0.046		
H - H - \emptyset	0.299	0.181	0.326	0.007	0.154	0.033		
M - H - Lat	0.274	0.201	0.311	0.005	0.167	0.041		
H - L - Lat	0.303	0.170	0.312	0.023	0.161	0.031		
M - L - Long	0.156	0.301	0.196	0.022	0.262	0.063		
H - H - Long	0.187	0.278	0.211	0.023	0.254	0.048		
M - L - 2 nd T	0.303	0.167	0.342	0.010	0.128	0.049		
H - H - 2 nd T	0.301	0.178	0.327	0.008	0.153	0.034		
-AIE-Fahrermodell (Abb. 5.23)								
L - L - \emptyset	0.336	0.003	0.013	0.324	0.324	0.000		
L - H - \emptyset	0.340	0.000	0.015	0.325	0.321	0.000		
M - L - \emptyset	0.338	0.000	0.010	0.328	0.325	0.000		
M - H - \emptyset	0.340	0.003	0.028	0.315	0.315	0.000		
H - L - \emptyset	0.371	0.000	0.112	0.259	0.259	0.000		
H - H - \emptyset	0.355	0.000	0.072	0.287	0.287	0.000	0.002	0.192
M - L - Lat	0.340	0.000	0.024	0.319	0.316	0.000		
H - L - Lat	0.376	0.000	0.124	0.252	0.248	0.000		
M - L - Long	0.336	0.000	0.012	0.327	0.324	0.000		
H - L - Long	0.369	0.000	0.112	0.262	0.257	0.000		
M - L - 2 nd T	0.339	0.000	0.012	0.324	0.324	0.000		
H - L - 2 nd T	0.369	0.000	0.110	0.262	0.259	0.000		
AIE ⁺ -Fahrermodell (Abb. 5.27)								
L - L - \emptyset	0.264	0.207	0.263	0.030	0.205	0.031		
L - H - \emptyset	0.278	0.189	0.281	0.032	0.184	0.036		
M - L - \emptyset	0.259	0.212	0.258	0.030	0.211	0.030		
M - H - \emptyset	0.269	0.196	0.273	0.033	0.191	0.037		
H - L - \emptyset	0.249	0.221	0.249	0.030	0.220	0.031		
H - H - \emptyset	0.278	0.188	0.276	0.035	0.189	0.034		
M - L - Lat	0.265	0.211	0.265	0.024	0.210	0.025	0.935	0.027
H - L - Lat	0.241	0.234	0.241	0.026	0.231	0.028		
M - L - Long	0.196	0.270	0.196	0.035	0.269	0.035		
H - L - Long	0.216	0.252	0.213	0.035	0.253	0.032		
M - L - 2 nd T	0.309	0.158	0.309	0.033	0.158	0.033		
H - L - 2 nd T	0.305	0.163	0.303	0.033	0.163	0.032		

Wird fortgesetzt ...

¹ Kodierung der Versuchsbedingungen: s. Tabelle B.2² $p_{X \rightarrow Y}$ bezeichnet die gerichtete Transitionswahrscheinlichkeit von X nach Y . Die Kürzel S, N und T stehen für: S = Straße, N = NRBT-Display, T = Tachometer.

... Fortsetzung von Tabelle C.8

Versuchs- ¹ bedingung	Transitionswahrscheinlichkeiten ²						R ²	RMSD		
	$p_{S \rightarrow N}$	$p_{S \rightarrow T}$	$p_{N \rightarrow S}$	$p_{N \rightarrow T}$	$p_{T \rightarrow S}$	$p_{T \rightarrow N}$				
AIE*-Fahrermodell										
L - L - \emptyset	0.260	0.232	0.261	0.008	0.228	0.010	0.925	0.035		
L - H - \emptyset	0.336	0.155	0.337	0.009	0.152	0.011				
M - L - \emptyset	0.248	0.246	0.249	0.006	0.242	0.009				
M - H - \emptyset	0.327	0.165	0.328	0.008	0.162	0.010				
H - L - \emptyset	0.247	0.249	0.248	0.005	0.241	0.010				
H - H - \emptyset	0.360	0.134	0.358	0.008	0.133	0.008				
M - L - Lat	0.262	0.232	0.262	0.007	0.228	0.008				
H - L - Lat	0.280	0.218	0.279	0.004	0.213	0.006				
M - L - Long	0.224	0.268	0.225	0.008	0.263	0.011				
H - L - Long	0.213	0.282	0.212	0.007	0.279	0.007				
M - L - 2 nd T	0.316	0.178	0.317	0.007	0.173	0.009				
H - L - 2 nd T	0.339	0.157	0.335	0.007	0.155	0.007				
SE ⁺ -Fahrermodell (Abb. 5.35)										
L - L - \emptyset	0.181	0.185	0.186	0.131	0.179	0.137			0.804	0.061
L - H - \emptyset	0.213	0.140	0.212	0.148	0.139	0.148				
M - L - \emptyset	0.206	0.195	0.203	0.101	0.197	0.098				
M - H - \emptyset	0.235	0.151	0.234	0.114	0.151	0.113				
H - L - \emptyset	0.256	0.180	0.254	0.066	0.180	0.065				
H - H - \emptyset	0.277	0.142	0.279	0.080	0.139	0.083				
M - L - Lat	0.208	0.204	0.210	0.087	0.201	0.090				
H - L - Lat	0.254	0.182	0.250	0.066	0.185	0.063				
M - L - Long	0.180	0.216	0.177	0.106	0.218	0.103				
H - L - Long	0.252	0.180	0.251	0.069	0.180	0.068				
M - L - 2 nd T	0.220	0.170	0.219	0.111	0.170	0.110				
H - L - 2 nd T	0.267	0.155	0.272	0.075	0.149	0.081				
S-AIE ⁺ -Fahrermodell (Abb. 5.36)										
L - L - \emptyset	0.182	0.184	0.281	0.035	0.185	0.034	0.931	0.029		
L - H - \emptyset	0.280	0.188	0.281	0.031	0.187	0.032				
M - L - \emptyset	0.277	0.191	0.275	0.034	0.191	0.032				
M - H - \emptyset	0.273	0.193	0.273	0.034	0.192	0.035				
H - L - \emptyset	0.256	0.215	0.254	0.030	0.215	0.030				
H - H - \emptyset	0.259	0.209	0.255	0.034	0.212	0.030				
M - L - Lat	0.289	0.182	0.291	0.028	0.180	0.030				
H - L - Lat	0.245	0.227	0.246	0.027	0.226	0.028				
M - L - Long	0.207	0.259	0.209	0.033	0.257	0.035				
H - L - Long	0.212	0.257	0.211	0.032	0.258	0.031				
M - L - 2 nd T	0.307	0.156	0.308	0.037	0.153	0.039				
H - L - 2 nd T	0.301	0.164	0.302	0.035	0.162	0.037				

¹ Kodierung der Versuchsbedingungen: s. Tabelle B.2² $p_{X \rightarrow Y}$ bezeichnet die **gerichtete Transitionswahrscheinlichkeit** von X nach Y . Die Kürzel S, N und T stehen für: S = Straße, N = NRBT-Display, T = Tachometer.

Tabelle C.9 – Kennwerte der Modellanpassungsgüte.


	<u>AIE⁺-Fahrermodell</u>				<u>AIE*-Fahrermodell</u>			
	R ²	RMSD	z	Regressionsgerade	R ²	RMSD	z	Regressionsgerade
PDTs	0.958	0.045	0.609	0.001 + 0.994 · x	0.960	0.113	1.628	-0.119 + 1.315 · x
f_{Gaze}	0.878	0.081 Hz	0.556	0.064 + 0.759 · x	0.731	0.215 Hz	1.741	-0.003 + 0.505 · x
Δt_{Gaze}	0.823	0.683 s	1.603	0.118 + 1.074 · x	0.832	0.696 s	2.028	-833 + 2.223 · x
$\Delta \text{ Lat}$	0.935	0.020 m	0.287	-0.009 + 1.070 · x	0.922	0.080 m	1.664	-0.139 + 1.276 · x
\bar{v}	0.707	1.34 km/h	0.879	53.40 + 0.455 · x	0.725	1.18 km/h	0.757	55.95 + 0.431 · x
$\overline{\Delta v}_{100}$	0.419	0.88 km/h	0.637	0.284 + 0.582 · x	0.680	0.71 km/h	0.427	0.602 + 0.492 · x
RT	0.127	444 ms	0.368	1927 + 0.112 · x	0.181	448 ms	0.350	1229 + 0.348 · x
	<u>SE⁺-Fahrermodell</u>				<u>S-AIE⁺-Fahrermodell</u>			
	R ²	RMSD	z	Regressionsgerade	R ²	RMSD	z	Regressionsgerade
PDTs	0.954	0.060	0.999	0.066 + 0.840 · x	0.960	0.042	0.582	0.007 + 0.977 · x
f_{Gaze}	0.702	0.104 Hz	0.726	0.196 + 0.588 · x	0.852	0.079 Hz	0.520	0.064 + 0.770 · x
Δt_{Gaze}	0.776	0.686 s	1.752	0.198 + 1.071 · x	0.830	0.683 s	1.621	134 + 1.060 · x
$\Delta \text{ Lat}$	0.203	0.165 m	3.534	0.320 + 0.294 · x	0.919	0.024 m	0.315	-0.032 + 1.134 · x
\bar{v}	0.740	2.00 km/h	1.364	9.410 + 0.887 · x	0.677	1.31 km/h	0.862	54.39 + 0.445 · x
$\overline{\Delta v}_{100}$	0.358	0.71 km/h	0.454	0.488 + 0.698 · x	0.540	0.85 km/h	0.614	-0.312 + 0.859 · x
RT	0.140	596 ms	0.537	2203 + 0.113 · x	0.176	944 ms	0.839	2102 + 0.364 · x

Anhang D

Prozedursyntax

Die wichtigsten syntaktischen Elemente der Prozedursprache werden nun in Form von Syntaxdiagrammen präsentiert. Begleitend wird kurz der Effekt der jeweiligen Elemente erläutert. Um die Prozedur für einen Agenten zu laden, wird in der [Agentenkonfigurationsdatei](#) der Name einer Prozedurdatei angegeben, die als Aufgabenbeschreibung eine Menge von Produktionsregeln beinhaltet, sowie einige Initialisierungsanweisungen (s. Syntaxdiagramm 1).

Syntaxdiagramm 1 Prozedur.



Jede Produktionsregel besteht aus drei Teilen: dem Regelkopf, der Regelbedingung oder auch **LHS** und den Regelaktionen oder **RHS** (s. Syntaxdiagramm 2).

Syntaxdiagramm 2 Produktionsregel.




D.1 Regelkopf

Eine Produktionsregel hat eine Reihe von Attributen, die im Regelkopf spezifiziert werden können (s. Syntaxdiagramm 3). Dabei erhält Produktionsregel Regel eine eindeutige Identifikationsnummer, die für die Visualisierung und Datenaufzeichnung der Simulation wichtig ist, jedoch keinen Einfluss auf die Semantik des kognitiven Agenten hat.

Das Feuereiner Produktionsregel dient immer dazu ein bestimmtes Ziel zu erreichen. Dieses wird ebenfalls im Regelkopf angegeben. Eine Regel wird nur verwendet, wenn das angegebene Ziel in der Zielkomponente aktiv ist.

Desweiteren wird der Typ der Produktionsregel definiert. CASCaS unterscheidet vier verschiedene Regeltypen: reguläre Regeln, reaktive Regeln, Wahrnehmungsregeln und Warteregeln. Diese werden in Abschnitt 2.3.6.2 näher beschrieben. Die übrigen Parameter sind optional und für die Integration des AIE-Modells nicht weiter von Interesse.


Syntaxdiagramm 3 Regelkopf.



D.2 Regelbedingung

Die Regelbedingung definiert den Zustand, in dem die Produktionsregel gefeuert werden soll. Streng genommen ist auch das Ziel, das im Regelkopf angegeben wird, Teil der Zustandsdefinition, da eine Produktionsregel nur gefeuert wird, wenn das angegebene Ziel aktiv ist. Die Regelbedingung formuliert jedoch nur Bedingungen an den Zustand der Gedächtniskomponente mithilfe einer Menge von **Retrieve**- und **Condition**-Kommandos (s. Syntaxdiagramm 4).

Syntaxdiagramm 4 Syntax der LHS-Elemente.



Über das **Retrieve**-Kommando wird geprüft, ob eine Information, die für eine Aktion auf der rechten Seite der Produktionsregel benötigt wird, in der Gedächtniskomponente enthalten und abrufbar ist. Dies geschieht basierend auf dem gewählten Algorithmus zur Bestimmung der Verfügbarkeit von Gedächtniselementen (s. Abschnitt 2.3.5).

Mittels des **Condition**-Kommandos lassen sich über boolesche Ausdrücke weitere Bedingungen an die Gedächtniselemente stellen, die erfüllt sein müssen, damit die Produktionsregel ausgeführt wird. In Abschnitt 2.3.5 wurde bereits aufgezeigt, dass mehrere strukturell identische Teilgraphen in der Gedächtniskomponente enthalten sein können. Erfüllen mehrere Teilgraphen die Regelbedingung, so wird einer ausgewählt, mit dem die Regel instantiiert wird. Die Aktionen, die beim Feuern der Produktionsregel ausgeführt werden, beziehen sich zum Teil auf diesen Teilgraphen.

D.3 Regelaktionen


Beim Feuern einer Produktionsregel, werden die Aktionen der **RHS** ausgeführt. Je nach Aktion werden Kommandos an die Gedächtnis-, Ziel- oder Motorkomponente

sowie die autonome Ebene gesendet.

Regelaktionen können Ausdrücke mit Gedächtnisdeskriptoren beinhalten. Diese können prinzipiell mehrdeutig sein (s. Abschnitt 2.3.5). Die Mehrdeutigkeiten werden durch ein Mapping der Deskriptoren auf das Gedächtnismuster, das durch die LHS gebildet wird, aufgelöst. Alle Deskriptoren innerhalb von Ausdrücken auf der RHS müssen sich auf das, durch die LHS definierte, Gedächtnismuster beziehen. Bei der Auswahl einer Regel wurde bereits eine konkrete, in der Gedächtniskomponente existierende Instanz des Musters identifiziert. Beim Feuern einer Produktionsregel werden nun die Gedächtnisdeskriptoren in den Regelaktionen durch die Werte dieser konkreten Instanz ersetzt.


Auf der RHS lassen sich sieben verschiedene Aktionstypen angeben (s. Syntaxdiagramm 5). Im Folgenden werden diese kurz beschrieben.

Syntaxdiagramm 5 RHS-Elemente.



LookAt-Kommando

Syntaxdiagramm 6 Das LookAt-Kommando.




Über das **lookAt**-Kommando lässt sich der visuelle Fokus des kognitiven Modells verändern. Benötigt wird dieses Kommando normalerweise, wenn eine bestimmte Information zur Bearbeitung einer Aufgabe erforderlich ist. Als Argument wird dem **lookAt**-Kommando ein Gedächtnisdeskriptor für die benötigte Information übergeben. Das Kommando wird an die Motorkomponente gesendet. Diese wählt aus der Umgebungstopologie eine Informationsquelle aus, die die gewünschte Information zur Verfügung stellt. Daraufhin wird eine Blickbewegung zur ausgewählten Informationsquelle initiiert.

Da zu einem Zeitpunkt immer nur eine Informationsquelle fixiert werden kann, können nicht mehrere **lookAt**-Kommandos gleichzeitig ausgeführt werden, es sei denn, die benötigten Informationen sind alle in der gleichen Informationsquelle verfügbar. Für den Fall, dass ein **lookAt**-Kommando noch nicht ausgeführt werden kann, verwaltet die Motorkomponente eine Liste, die die noch nicht behandelten **lookAt**-Kommandos enthält. In der Warteschlangentheorie entspricht dies einer Situation mit Single-Server Queue. Die Liste wird nach dem **FIFO**-Prinzip bearbeitet, so dass sich der nächste Blick des kognitiven Agenten immer auf eine geeignete Informationsquelle für das erste Element in der Liste richtet. Sobald die Informationen der aktuellen Informationsquelle wahrgenommen und im Gedächtnis abgelegt wurden, werden alle Kommandos aus der Liste entfernt, die über diese Informationsquelle Informationen beziehen wollen. Ein vergleichbarer Queuing-Mechanismus wird

auch im Visual Strategies Manager von COSMODRIVE verwendet (Bornard et al., 2011). COSMODRIVE ermöglicht es zudem die Dringlichkeit der benötigten Information über eine Priorität anzugeben, die bei Bearbeitung der Liste berücksichtigt wird. Dies ist in CASCaS nicht möglich. Allerdings beinhaltet die Warteliste typischerweise nur ein oder zwei Kommandos. Für die Wahrnehmungsregeln spielen die **LookAt**-Kommandos eine besondere Rolle (s. Abschnitt 2.3.6.2).

Goal-Kommando

Syntaxdiagramm 7 Das Goal-Kommando.



Die Zielagenda lässt sich mittels dreier **Goal**-Kommandos beeinflussen (s. Syntaxdiagramm 7). Neue Ziele werden über das einfache **Goal**-Kommando durch Angabe des Zielnamens der Zielagenda hinzugefügt. Der Standardmodus für ein Ziel ist *transient*, kann jedoch explizit über den **mode**-Parameter angegeben werden. Mit dem AIE-Modell sind zwei weitere Parameter hinzugekommen. Der Wertparameter eines Ziels für das AIE-Modell lässt sich über das Schlüsselwort **value** angeben. Optional kann auch der Erwartungsparameter über das Schlüsselwort **expectancy** fest vorgegeben werden. Dies wurde bei der Evaluierung genutzt, um den Effekt der **Ereignisfunktion** zu untersuchen (s. Abschnitt 4.3.3 und 5.8.4).

In Abbildung D.1 ist beispielhaft dargestellt, wie Kommandos die Zielagenda verändern. Produktionsregel 1 fügt für die Bearbeitung des Ziels T zwei Unterziele der Zielagenda hinzu, deren Verarbeitungsreihenfolge nicht vorgegeben ist.

Die anderen beiden Kommandos sind vor allem für persistente Ziele interessant. Das **GoalDone**-Kommando ist der einzige Weg, um ein persistentes Ziel vor Ende der Simulation von der Zielagenda zu entfernen. Wird kein Name des zu entfernenden Ziels angegeben, wird das momentan aktive Ziel entfernt. Dies ist in Abbildung D.1 bei Produktionsregel 2 für das persistente Ziel A zu sehen.

Das **GoalContinue**-Kommando dagegen verhindert, dass ein aktives Ziel nach der Ausführung einer Regel in den Zustand *Selectable* übergeht. So lässt sich verhindern, dass Aktionssequenzen, die untrennbar zusammengehören, aber durch mehr als eine

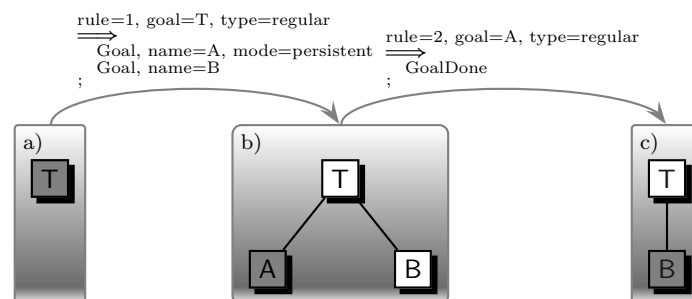



Abbildung D.1 – Beispielhafte Darstellung, wie sich der Zustand der Zielagenda (a-c) durch Verwendung der **Goal**-Kommandos verändern lässt. Das jeweils aktive Ziel ist grün markiert.

Regel erzeugt werden, von einer anderen Aufgabe unterbrochen werden.

Motor-Kommando

Syntaxdiagramm 8 Das Motor-Kommando.



Motorische Aktionen lassen sich über das **Motor**-Kommando initiieren (s. Syntaxdiagramm 8). Das Kommando erwartet als Parameter den Körperteil, der die Interaktion durchführt (linke/rechte Hand, bzw. linker/rechter Fuß), die Art der Interaktion (z.B.: **PUSH**), sowie das Bedienelement, mit dem interagiert wird. Für einige Interaktionsarten muss zudem ein weiterer Wert angegeben werden, der die Interaktion noch detaillierter beschreibt. Wenn das Durchführen einer motorischen Aktion eine visuelle Kontrolle benötigt, so muss die Informationsquelle angegeben werden, die das erforderliche Feedback liefert. Das Einstellen der Klimaanlage auf eine Temperatur von 20.0° kann so beispielsweise wie folgt ausgedrückt werden:


```
Motor, right hand, adjust, instrument=air_conditioning.control,...
...value=20.0, feedback=air_conditioning.display
```

Dabei bezeichnet `air_conditioning.control` das Bedienelement (zum Beispiel ein Drehschalter) und `air_conditioning.display` eine Digitalanzeige, auf der die aktuell eingestellte Temperatur angezeigt wird.

Voice-Kommando

Für Sprachaktionen stellt die Motorkomponente ein **voice**-Kommando zur Verfügung. Es erwartet als Parameter die gesprochene Nachricht in Textform, die Semantik der Nachricht in Form von Variablenzuweisungen sowie einen Bezeichner für den Empfänger der Nachricht. Dieses Kommando kann zum Beispiel verwendet werden, um mehrere kognitive Agenten direkt miteinander interagieren zu lassen.

Syntaxdiagramm 9 Das Voice-Kommando.




Skill-Kommando

Da Skills auf der autonomen Ebene durch anwendungsspezifische Skills implementiert werden können, ist die Definition des **skill**-Kommandos sehr generisch. Es muss lediglich ein Bezeichner für den Skill sowie das Kommando, das dem Skill übermittelt werden soll, angegeben werden. Die Syntax des Kommandos wird durch die jeweilige Skillimplementierung definiert. Lediglich das Schlüsselwort **stop** ist reserviert, um die Ausführung eines Skills zu beenden. Ein analoges Schlüsselwort **start** existiert nicht. Die Ausführung beginnt, sobald das erste Kommando an den betreffenden Skill adressiert wird.

Syntaxdiagramm 10 Das Skill-Kommando.

Memorize-Kommando


Über das **Memorize**-Kommando lässt sich ein neues Element dem Gedächtnismodell hinzufügen oder ein bestehendes aktualisieren. Der erste Parameter des Kommandos ist der Gedächtnisdeskriptor für das Element (s. Syntaxdiagramm 11).

Syntaxdiagramm 11 Das Memorize-Kommando.

Der Wert des Gedächtniselements ergibt sich aus dem Ausdruck, der im zweiten Parameter des Kommandos spezifiziert wird. Dies soll am Beispiel in Abbildung D.2 verdeutlicht werden, das zudem das Mapping der Gedächtnisdeskriptoren von RHS zu LHS illustriert. In der Abbildung ist eine Produktionsregel zu sehen, die beschreibt, dass das Modell beim Erblicken eines Schild zur Geschwindigkeitsbegrenzung, die eigene Zielgeschwindigkeit an der maximal erlaubten Geschwindigkeit ausrichtet und hierfür ein entsprechendes Element in der Gedächtniskomponente anlegt.

Associate-Kommando

Auch über das **Associate**-Kommando lässt sich das Gedächtnismodell beeinflussen. Es werden jedoch keine neuen Einträge angelegt, sondern lediglich Assoziationen zwischen bestehenden Einträgen erzeugt. Daher ist der zweite Parameter hier kein Ausdruck, sondern ebenfalls ein Gedächtnisdeskriptor, der das Ziel der neuen Assoziation angibt.

Syntaxdiagramm 12 Das Associate-Kommando.

Dies wird wieder anhand eines Beispiels in Abbildung D.3 veranschaulicht. Durch das **Associate**-Kommando in Produktionsregel 1 assoziiert das Modell dort die Information, dass das vorausfahrende Fahrzeug kurz vor einer Kreuzung blinkt, damit das Fahrzeug an dieser Kreuzung abbiegen wird.

D.4 Komponenteninitialisierung

Die Prozedurdatei enthält neben den Produktionsregeln auch optionale Abschnitte zur Initialisierung der einzelnen Komponenten. Dies wird vor allem genutzt, um das Ziel zu bestimmen, das zu Beginn der Simulation das einzige Ziel der Zielagenda ist. Zudem lassen sich Gedächtniselemente angeben, die vor Beginn der Simulation in die Gedächtniskomponente eingefügt werden.

Für Skills lassen sich benutzerdefinierte Initialisierungsabschnitte angeben, um zum Beispiel eine parametrisierte Ausführung zu ermöglichen, oder um zusätzlich Daten vor Beginn der Simulation zu laden.

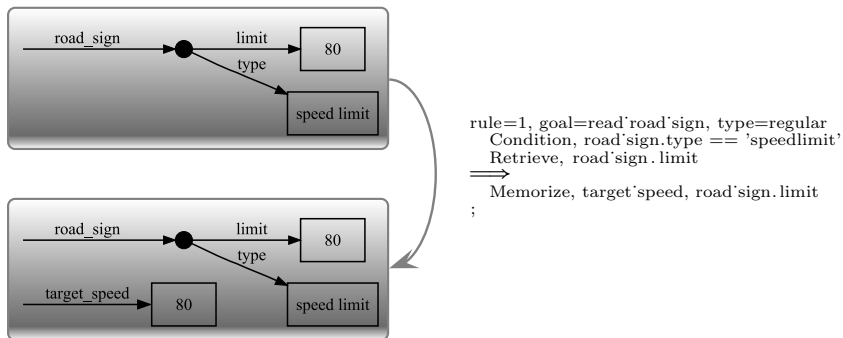


Abbildung D.2 – Bei der Auswahl der Regel 1 wird ein durch die LHS spezifiziertes Muster im Gedächtnis identifiziert (links oben). Durch das **Memorize**-Kommando wird ein neues Element **target_speed** in der Gedächtniskomponente erzeugt (links unten). In diesem Fall ergibt sich der Wert des Elements aus dem Mapping des Ausdrucks **road_sign.limit** auf die durch die LHS identifizierte Gedächtnisstruktur.

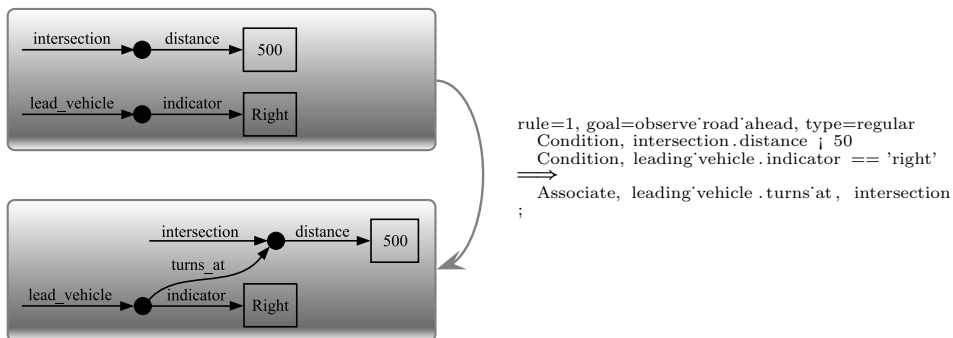


Abbildung D.3 – Bei der Auswahl der Produktionsregel 1 wird das Blinken des vorausfahrenden Fahrzeugs mit der Information zur Entfernung der nächsten Kreuzung verknüpft. Dabei wird durch das **Associate**-Kommando die Assoziation **turns_at** erzeugt (unten links).

Anhang E

Identifikation der freien Parameter

Die additive Variante des AIE-Modells besitzt einen freien Parameter, während die multiplikative Variante keinen freien Parameter besitzt. Dies ergibt sich, wenn in die Berechnung der Zielauswahlwahrscheinlichkeit (Gleichung 3.2, S. 70) die Definition des Aufmerksamkeitsgewichts $w(g)$ (Gleichung 3.1) in der additiven bzw. multiplikativen Variante eingesetzt wird.

Bei Verwendung der additiven Variante lässt sich Gleichung 3.2 wie folgt umschreiben:

$$\begin{aligned}
 P(g_i) &= \frac{w(g_i)}{\sum_{g_j \in G} w(g_j)} && \text{[Einsetzen von Gleichung 3.1]} \\
 &= \frac{U \cdot \frac{u_{g_i}}{\sum_{g_j \in G} u_{g_j}} + V \cdot \frac{v_{g_i}}{\sum_{g_j \in G} v_{g_j}}}{\sum_{g_j \in G} \left(U \cdot \frac{u_{g_j}}{\sum_{g_k \in G} u_{g_k}} + V \cdot \frac{v_{g_j}}{\sum_{g_k \in G} v_{g_k}} \right)} && \left. \begin{array}{l} \text{Konstante Faktoren } U, V, \\ \sum_{g_k \in G} u_{g_k} \text{ und } \sum_{g_k \in G} v_{g_k} \text{ vor die} \\ \text{Summenformeln ziehen} \end{array} \right\} \\
 &= \frac{U \cdot \frac{u_{g_i}}{\sum_{g_j \in G} u_{g_j}} + V \cdot \frac{v_{g_i}}{\sum_{g_j \in G} v_{g_j}}}{\frac{U}{\sum_{g_k \in G} u_{g_k}} \cdot \sum_{g_j \in G} u_{g_j} + \frac{V}{\sum_{g_k \in G} v_{g_k}} \cdot \sum_{g_j \in G} v_{g_j}} \\
 &= \frac{U \cdot \frac{u_{g_i}}{\sum_{g_j \in G} u_{g_j}} + V \cdot \frac{v_{g_i}}{\sum_{g_j \in G} v_{g_j}}}{U + V} \cdot \frac{\frac{1}{V}}{\frac{1}{V}} && \text{[erweitern mit } \frac{1}{V}, (V > 0)\text{]} \\
 &= \frac{\frac{U}{V} \cdot \frac{u_{g_i}}{\sum_{g_j \in G} u_{g_j}} + \frac{v_{g_i}}{\sum_{g_j \in G} v_{g_j}}}{\frac{U}{V} + 1}
 \end{aligned}$$

Somit bleibt bei der additiven Variante des AIE-Modells das Verhältnis U/V als einziger freier Parameter.

Bei Verwendung der multiplikativen Variante lässt sich Gleichung 3.2 wie folgt umschreiben:

$$\begin{aligned}
 P(g_i) &= \frac{w(g_i)}{\sum_{g_j \in G} w(g_j)} \\
 &= \frac{U \cdot \frac{u_{g_i}}{\sum_{g_j \in G} u_{g_j}} \cdot V \cdot \frac{v_{g_i}}{\sum_{g_j \in G} v_{g_j}}}{\sum_{g_j \in G} \left(U \cdot \frac{u_{g_j}}{\sum_{g_k \in G} u_{g_k}} \cdot V \cdot \frac{v_{g_j}}{\sum_{g_k \in G} v_{g_k}} \right)} \\
 &= \frac{\cancel{U \cdot V} \cdot \frac{u_{g_i} \cdot v_{g_i}}{\sum_{g_j \in G} u_{g_j} \cdot v_{g_j}}}{\sum_{g_j \in G} \frac{\cancel{U \cdot V}}{\sum_{g_k \in G} u_{g_k} \cdot v_{g_k}} \cdot \sum_{g_j \in G} (u_{g_j} \cdot v_{g_j})} \\
 &= \frac{u_{g_i} \cdot v_{g_i}}{\sum_{g_j \in G} (u_{g_j} \cdot v_{g_j})}
 \end{aligned}$$

Konstante Faktoren U , V ,
 $\sum_{g_k \in G} u_{g_k}$ und $\sum_{g_k \in G} v_{g_k}$ vor die
 Summenformeln ziehen

Somit hat die multiplikative Variante des AIE-Modells keinen freien Parameter.

Glossar

Agentenkonfigurationsdatei Definiert die Konfiguration für CASCaS zur Simulation eines kognitiven Agenten. Dies beinhaltet die Definition der Aufgabenbeschreibung, der Simulationsumgebung, dem Data-Logging sowie einige Parameter zu einzelnen Prozessen in CASCaS.

Ablaufplanungsalgorithmus Als Ablaufplanungsalgorithmus bezeichnet [Moray \(1986\)](#) einen von zwei für Blickbewegungen relevanten Mechanismen, der entscheidet, in welcher Reihenfolge verschiedene Informationsquellen betrachtet werden. Die Dauer eines Blickes wird dagegen durch den [Datenakquisealgorithmus](#) bestimmt.

ambiente Wahrnehmung Die ambiente (visuelle) Wahrnehmung ist zuständig für die zumeist unbewusste Wahrnehmung der eigenen Position und der Bewegung im Raum. Sie bezieht ihre Informationen sowohl aus dem [fovealen](#) als auch [peripheren Blickfeld](#).

attentives Merkmal Attentive Merkmale benötigen eine Fokussierung der Aufmerksamkeit auf das Merkmal, um wahrgenommen zu werden. Die Wahrnehmung ist daher meistens [foveal](#) und bewusst. Typische Beispiele für attentive Merkmale sind Entfernungen und Objektidentifikationen.

Aufmerksamkeitsgewicht Das Aufmerksamkeitsgewicht einer Informationsquelle oder einer Aufgabe ist eine relative Größe, über die die Wahrscheinlichkeit ausgedrückt wird, dass die Aufmerksamkeit auf die Informationsquelle bzw. Aufgabe gerichtet wird.

Aufgabenpriorität Über die Aufgabenpriorität wird ausgedrückt, wie wichtig eine Aufgabe ist. In dieser Arbeit wird die Aufgabenpriorität wie bei [Wickens et al. \(2003a\)](#) als relatives Maß definiert, mit dem beschrieben wird, ob eine Aufgabe wichtiger, gleich wichtig oder unwichtiger als eine andere Aufgabe ist. Dies wird in dieser Arbeit mithilfe des [Lowest-Ordinal-Algorithmus](#) ausgedrückt, mit dem eine Ordnungsrelation über allen Aufgaben gebildet wird, die in einem Versuchsszenario betrachtet werden.

Aufgabenprozedur Die Beschreibung, wie eine Aufgabe im Detail zu bearbeiten ist, wird als Aufgabenprozedur oder Aufgabenmodell bezeichnet. Typischerweise werden regelbasierte Beschreibungssprachen für die Erstellung der Aufgabenprozedur verwendet.

Bandbreite Die Bandbreite bezeichnet in der Datenübertragung die Menge an Informationen, die pro Zeiteinheit über einen Kanal kommuniziert werden kann und wird typischerweise in bit/s angegeben. Leicht abweichend wird in der

Signalverarbeitung mit der Bandbreite eines physikalischen Signals die Differenz zwischen oberen und unteren Grenzfrequenz bezeichnet. Die maximale Datenrate, die über einen physikalischen Kommunikationskanal übertragen werden kann, hängt proportional von der Bandbreite des physikalischen Signals ab. In der Literatur zur menschlichen Aufmerksamkeit werden daher beide Definitionen verwendet. So beziehen sich [Senders \(1964\)](#) und [Carbo-nell \(1966\)](#) auf die physikalische Bandbreite, während sich z.B. [Wickens und McCarley \(2008\)](#) oder [Miller et al. \(2004\)](#) auf die Datenrate beziehen.

Bandbreite Die Informationsbandbreite bezeichnet die Menge an Informationen, die pro Zeiteinheit kommuniziert werden kann und wird typischerweise in bit/s angegeben. (s. a. [Bandbreite](#)).

Bankett Im Straßenbau bezeichnet das Bankett den Teil der Straße, der nur leicht befestigt ist (z. B. durch Grasbewuchs und Schotter) und ebenerdig an die befestigte Fahrbahn anschließt. Die Breite des Banketts wird durch die Richtlinien für die Anlage von Straßen ([Forschungsgesellschaft für Straßen- und Verkehrswesen, 1996b](#)) definiert.

Bestimmtheitsmaß Im Zusammenhang mit prädiktiven Modellen ist das Bestimmtheitsmaß (oder Determinationskoeffizient) das Verhältnis der Variabilität der vom Modell vorhergesagten Werte (\hat{Y}) zur Variabilität der gemessenen Werte (Y): $R^2 = \frac{\sum_i(\hat{y}_i - \bar{y})^2}{\sum_i(y_i - \bar{y})^2}$ ([Bortz und Schuster, 2010](#)). Es ist gleich dem Quadrat des [Korrelationskoeffizienten](#) nach Pearson.

Blick Aufeinanderfolgende Fixationen innerhalb der selben Informationsquelle inklusive der verbindenden Sakkaden.

Blickablenkungsdauer Zeitdauer zwischen zwei Fixationen auf die gleiche Informationsquelle. Gemessen wird die Zeit, sobald der Blickpunkt die Informationsquelle verlässt bis zum ersten Zeitpunkt, an dem er wieder innerhalb der Informationsquelle ist ($\hat{=}$ *duration of diversion* in ISO 15007-1:2002 ([ISO, 2002](#))).

Blickfrequenz Die Blickfrequenz gibt die durchschnittliche Anzahl an Blicken pro Sekunde zu einer Informationsquelle an. Zwei Blicke sind dabei immer durch mindestens einen Blick zu einer anderen Informationsquelle getrennt. Die Blickfrequenz bezieht sich daher immer auf eine einzelne Informationsquelle (vgl. *Gesamtblickfrequenz*). ($\hat{=}$ *glance frequency* in ISO 15007-1:2002 ([ISO, 2002](#))).

Bottom-Up-Aufmerksamkeitskontrolle s. [exogene Aufmerksamkeitskontrolle](#).

Buffer Jedes ACT-R-Modul besitzt einen Buffer als Interface zum zentralen prozeduralem Modul, in dem jeweils maximal ein [Chunk](#) abgelegt werden kann. Über das Buffer-Konzept wird in ACT-R die Ressourcenbeschränkung der zentralen Wissensverarbeitung simuliert ([Anderson et al., 2004](#)).

Chunk Ein Chunk bezeichnet eine Menge von Informationen, die im Gedächtnis als eine zusammenhängende Wissensseinheit codiert ist. So lassen sich die Buchstaben 'C', 'h', 'u', 'n', 'k' als eine Wissensseinheit – dem Wort 'Chunk' – codieren. Wie Informationen gruppiert werden, ist individuell verschieden ([Miller, 1956](#)).

Closed-Loop-Simulation Die Closed-Loop-Simulation bezeichnet eine Simulation eines Systems mit einem geschlossenen Regelkreis.

Datenakquisealgorithmus Nach Moray (1986) bezeichnet der Datenakquisealgorithmus einen von zwei für Blickbewegungen relevanten Mechanismen, der bestimmt, wie lange eine Informationsquelle betrachtet wird. Die Frage nach der Blickreihenfolge zu verschiedenen Informationsquellen wird dagegen durch den Ablaufplanungsalgorithmus bestimmt.

Einheitsmatrix Eine Einheitsmatrix ist eine quadratische Matrix, bei der alle Elemente den Wert 0 haben, bis auf die Elemente der Hauptdiagonalen, die den Wert 1 haben.

endogene Aufmerksamkeitskontrolle Die endogene Aufmerksamkeitskontrolle beschreibt gewollte und beabsichtigte Veränderungen des Aufmerksamkeitsfokus (Theeuwes, 1991), wie z. B. der Blick auf die Uhr, um die aktuelle Uhrzeit zu bestimmen.

Ereignis Werden zum Zeitpunkt t Informationen, die zum Erreichen eines Ziels g von Relevanz sind, genutzt, um dieses Ziel zu erreichen, so wird von einem Ereignis $e = (g, t)$ gesprochen. Diese Definition ist abgeleitet aus Millers (1953) Überlegung, dass bevor ein menschlicher Operator eine Aktion zur Erreichung eines Ziels durchführt, er typischerweise zuerst alle nötigen Informationen bezieht und auf Basis dieser Informationen entscheidet, ob eine Aktion notwendig ist (s. Abschnitt 3.3.1).

Ereignisfunktion Für ein Aufgabenziel g wird die durch die Simulationszeit von g geteilte kumulierte Häufigkeitsverteilung der Ereignisabstände als Ereignisfunktion von g bezeichnet: $ef_g(\Delta t) = \frac{H_g(\Delta t)}{d_g}$. Mit der Ereignisfunktion von g kann somit, basierend auf den bisher beobachteten Ereignissen, die Wahrscheinlichkeit bestimmt werden, dass ein Ereignis nicht später als Δt Zeiteinheiten nach dem vorherigen Ereignis auftritt (s. Abschnitt 3.3.3).

Ereignisrate Die Ereignisrate eines Ziels gibt an wie viel Ereignisse pro Sekunde für ein Aufgabenziel auftreten (s. Abschnitt 3.3.2). Die Ereignisrate eines Ziels wird in dieser Arbeit als Maß für die Bandbreite eines Ziels verwendet, da sie angibt wie häufig Informationen vorliegen, auf die der Menschen reagieren muss, um das Aufgabenziel zu erreichen.

exogene Aufmerksamkeitskontrolle Die exogene Aufmerksamkeitskontrolle beschreibt unbeabsichtigte und durch äußere Reize getriebene Veränderungen des Aufmerksamkeitsfokus (Theeuwes, 1991), wie z. B. der Blick in Richtung eines plötzlich auftretenden Alarmons.

Expected-Value-Modell Das Expected Value Modell ist eine Variante des SEEV-Modells, bei der nur die Top-Down-Faktoren berücksichtigt werden. Alle bisherigen Anwendungen in der Literatur nutzen eine multiplikative Verbindung der Erwartungs- und Wertparameter, sowie eine zusätzliche Relevanzmatrix R , die die Relevanz jeder Informationsquelle A für jede Aufgabe g angibt. Das Aufmerksamkeitsgewicht einer Informationsquelle A wird vom Expected Value Modell bestimmt durch $BW_A \cdot \sum_{g \in G} (R_{A,g} \cdot V_g)$, mit dem Informationswert V und der Informationsbandbreite BW als Proxy für die Erwartung.

Eye-Mind-Assumption Bei Voraussetzung der Eye-Mind-Assumption wird davon ausgegangen, dass der Blick immer auf eine Informationsquelle gerichtet ist, die für die Aufgabe, auf die die mentale Aufmerksamkeit momentan gerichtet ist, von Bedeutung ist (Just und Carpenter, 1980).

Fehler 1. Art (auch α -Fehler) Wird beim Hypothesentesten die Nullhypothese fälschlicherweise zurückgewiesen, so spricht man von einem Fehler 1. Art.

Fehler 2. Art (auch β -Fehler) Wird beim Hypothesentesten die Nullhypothese fälschlicherweise beibehalten, so spricht man von einem Fehler 2. Art.

First In, First Out Prinzip zur Organisation von Warteschlangen. Das nächste Element, das der Warteschlange entnommen wird, ist immer das Element, das die längste Zeit in der Warteschlange gewartet hat.

Fixation Ausrichtung der Augen auf ein fixiertes Ziel für eine bestimmte Mindestdauer ($\hat{=}$ *fixation* in ISO 15007-1:2002 (ISO, 2002)).

fokale Wahrnehmung Die fokale (visuelle) Wahrnehmung ist zuständig für die visuelle Identifizierung von Objekten und das Erkennen von Detailinformationen. Sie bezieht ihre Informationen fast ausschließlich aus der **Fovea** und führt meist zu bewussten Wahrnehmungen.

Fovea Die Fovea ist der Bereich der Retina mit der höchsten Auflösung. Hier treffen die Reize auf, die im visuellen Fokus liegen.

foveales Sichtfeld Das foveale Sichtfeld beschreibt den Bereich der visuellen Wahrnehmung, der innerhalb der **Fovea** wahrgenommen wird. Der Bereich, der außerhalb der Fovea wahrgenommen wird, wird **peripheres Sichtfeld** genannt.

gerichtete Transitionswahrscheinlichkeit Die gerichtete Transitionswahrscheinlichkeit gibt die relative Häufigkeit von Blicktransitionen von einer Informationsquellen zu einer anderen Informationsquelle im Verhältnis zur Anzahl aller Blicktransitionen an. (siehe auch *Transitionswahrscheinlichkeit*).

Gesamtblickfrequenz Die Gesamtblickfrequenz gibt die durchschnittliche Anzahl an Blickwechseln zwischen allen betrachteten Informationsquellen pro Sekunde an. Der Begriff Blickfrequenz wird dagegen immer im Zusammenhang zu einer einzelnen Informationsquelle verwendet (vgl. *Blickfrequenz*).

gleichmäßige Konvergenz Eine Funktionenfolge f_n konvergiert gleichmäßig gegen eine Grenzfunktion f , wenn die maximale Differenz zwischen der Funktionenfolge und der Grenzfunktion, die sich an einer beliebigen Stelle im Definitionsbereich D der Funktion befindet, für $n \rightarrow \infty$ gegen 0 konvergiert. Es gilt dann: $\lim_{n \rightarrow \infty} \sup_{x \in D} |f(x) - f_n(x)| = 0$ (Derwent und Weisstein, 2013).

Grenzfunktion Konvergiert eine Funktionenfolge f_n , so wird ihr Grenzwert Grenzfunktion f genannt. Es lassen sich verschiedene Konvergenzeigenschaften für Funktionen unterscheiden. Bei der punkweisen Konvergenz konvergiert jeder Punkt $f_n(x)$ der Funktionenfolge gegen den Wert der Grenzfunktion $f(x)$ (Weisstein, 2013b). Bei der gleichmäßigen Konvergenz konvergiert der maximale Unterschied zwischen der Funktionenfolge und der Grenzfunktion gegen 0 (Derwent und Weisstein, 2013).

Human-in-the-Loop-Simulation Human-in-the-Loop-Simulationen bezeichnen computergestützte Simulationen, bei denen auch menschliche Versuchspersonen involviert sind, die mit der Softwaresimulation interagieren (vgl. [Closed-Loop-Simulation](#)).

Immediacy-Annahme Die Immediacy-Annahme besagt, dass die Dauer einer Blickfixation der Dauer entspricht, die benötigt wird, um die gesuchten Informationen im Blickfeld wahrzunehmen und zu verarbeiten ([Just und Carpenter, 1980](#)).

Inflation des Fehlers 1. Art Werden m unabhängige Hypothesentests auf dem gleichen Datensatz durchgeführt, so wird bei jedem Hypothesentest die Wahrscheinlichkeit, dass die Nullhypothese fälschlicherweise verworfen wird, durch das Signifikanzniveau α begrenzt. Die Wahrscheinlichkeit, dass dies mindestens bei einer Nullhypothese geschieht, ist mit $1 - (1 - \alpha)^m$ jedoch bedeutend größer ([Bortz und Schuster, 2010](#)) und steigt mit der Anzahl der Hypothesen. Dies wird als Inflation des Fehlers 1. Art bezeichnet und sollte mit einer geeigneten Korrektur der Signifikanzniveaus für die einzelnen Hypothesentest ausgeglichen werden ([Bortz und Schuster, 2010](#)).

Infotainmentsystem Ein Infotainmentsystem dient dazu sowohl informierende Inhalte zu präsentieren, wie Informationen der Assistenz- und Navigationssysteme, als auch unterhaltende Medien, wie das aktuelle Lied einer momentan wiedergegebenen Audi-CD. Im Automobilbereich verschmelzen diese System immer mehr und werden häufig und dem Begriff Infotainmentsystem zusammengefasst.

Integralglied Ein Integralglied ist eine Komponente, die in vielen Reglern verwendet wird. Das Ausgangssignal wird gebildet durch die Aufsummierung des Eingangssignal $e(t)$ (Integration) und Verstärkung um einen konstanten Faktor K : $u(t) = K \cdot \int_0^t e(x) dx$.

Klothoide Eine Klothoide ist eine Kurve, deren Krümmung linear mit der Länge des Kurvenbogens zunimmt. Klothoidensegmente werden im Straßen- und Schienenbau genutzt, um Streckensegmente mit unterschiedlicher, aber konstanter Krümmung zu verbinden, da die Querbeschleunigung beim Durchfahren einer Klothoiden linear zu- bzw. abnimmt. Eine vollständige Klothoide ist in Parameterform mit konstantem a definiert durch: $\left(\begin{matrix} a\sqrt{\pi} \cdot \int_0^t \cos(\frac{1}{2}\pi u^2) du \\ a\sqrt{\pi} \cdot \int_0^t \sin(\frac{1}{2}\pi u^2) du \end{matrix} \right)$ ([Bronstein et al., 2008, S. 107](#)).

Kognitive Architektur Eine kognitive Architektur integriert verschiedene Modelle zu Strukturen und Prozessen der menschlichen Kognition in ein gemeinsames Rahmenwerk.

Kognitiver Agent Die Kombination aus Aufgabenprozedur und kognitiver Architektur wird als kognitiver Agent bezeichnet.

Kognitives Modell Als kognitives Modell wird ein Modell zu einem bestimmten Aspekt der Kognition bezeichnet, wie zum Beispiel der Aufmerksamkeit oder Wahrnehmung.

Korrelationskoeffizient Der Korrelationskoeffizient ist ein Maß, um Zusammenhänge zweier Variablen X und Y zu beschreiben. Der Korrelationskoeffizient ist invariant gegenüber Maßstabsveränderungen der beiden Variablen. Er wird gebildet, indem die Kovarianz von X und Y durch das Produkt der Standardabweichungen von X und Y geteilt wird (Bortz und Schuster, 2010).

kumulierte Häufigkeitsverteilung Die kumulierte Häufigkeitsverteilung $H(x)$ einer Zufallsvariablen X gibt an, wie häufig für X ein Wert kleiner als x beobachtet wurde.

Lateralkontrolle Im Kontext dieser Arbeit bezeichnet die Lateralkontrolle die Aufgabe des Fahrers die Querbewegung des Fahrzeugs angemessen zu kontrollieren. Dies beinhaltet u. a. das sichere Führen des Fahrzeugs innerhalb der Spur bei geraden und kurvigen Strecken oder das Wechseln einer Spur, um beispielsweise zu überholen.

Longitudinalkontrolle Im Kontext dieser Arbeit bezeichnet die Longitudinalkontrolle die Aufgabe des Fahrers die Geschwindigkeit und Beschleunigung des Fahrzeugs in Fahrtrichtung angemessen zu kontrollieren. Dies beinhaltet u. a. das Einhalten einer Zielgeschwindigkeit, das Wahren eines Sicherheitsabstands zu vorausfahrenden Fahrzeugen oder das Anhalten vor Ampeln.

Lowest-Ordinal-Algorithmus Der Lowest Ordinal Algorithmus ist ein Verfahren, um die Parameter des SEEV-Modells festzulegen. Für jeden Faktor des SEEV-Modells werden jeweils alle zu untersuchenden Situationen betrachtet. Die Situationen werden vom Analysten entsprechend der zu erwartenden Faktorausprägung in eine Rangfolge gebracht. Die tatsächliche Faktorausprägung, die im SEEV-Modell für eine bestimmte Situation verwendet wird, wird durch den ganzzahligen Wert der Position in der Rangfolge geschätzt (Wickens et al., 2003a).

mentale Aufmerksamkeit Der Begriff der mentalen Aufmerksamkeit beschreibt in dieser Arbeit die Aufgabe, die zur Zeit mental verarbeitet wird. Sie ist immer genau auf eine Aufgabe gerichtet bzw. das Ziel, das durch die Aufgabe erreicht werden soll. Aufmerksamkeit und mentale Aufmerksamkeit werden in dieser Arbeit synonym verwendet. Diese Definition unterscheidet sich leicht von anderen gängigen Definitionen vor allem dadurch, dass der Fokus der mentalen Aufmerksamkeit die Aufgabe selbst ist und nicht die Dinge in der Umgebung, mit denen sich die Aufgabe beschäftigt. (vgl. [visuelle Aufmerksamkeit](#)).

Methode der kleinsten Quadrate Die Methode der kleinsten Quadrate wird genutzt, um die freien Parameter einer Funktionsfamilie zu bestimmen, so dass die resultierende Funktion möglichst gut eine Menge von Datenpunkten beschreibt. Dabei wird die quadratische Abweichung der Datenpunkte zu den Funktionswerten minimiert.

Mock-up Als Mock-up wird die Attrappe oder der Prototyp eines Systems bezeichnet, der zwar grundlegende Merkmale wie Aussehen, Form oder Reaktionszeiten besitzt, ansonsten aber funktionslos ist.

Modellanpassungsgüte Die Modellanpassungsgüte beschreibt wie gut ein Modell die tatsächlichen Messwerte wiedergibt. Als Maße für die Modellanpassungsgüte wurden in dieser Arbeit vor allem das **Bestimmtheitsmaß** verwendet, um die Güte des Modelltrends zu beschreiben, sowie die **Root-Mean-Square Deviation** und **Z-Transformationen**, um die absoluten Abweichungen zwischen Modell und Messwerten zu beschreiben.

Monitoring Im Zusammenhang mit dieser Arbeit bezeichnet Monitoring das kontinuierliche Überwachen eines oder mehrerer Prozesse. Dabei muss der Zustand des Prozesses vom Überwacher regelmäßig aktiv überprüft werden.

Out-of-the-Loop Out-of-the-Loop ist ein Begriff der bei der Automatisierung von Kontrollprozessen genutzt wird, um zu beschreiben, inwieweit der menschliche Operator in die Kontrolle eingebunden ist. Ist der Operator in die Kontrolle eingebunden und über den Systemzustand vollständig informiert, so wird dies als In-the-Loop bezeichnet. Ist der Operator jedoch nicht an der Kontrolle beteiligt und nicht über den Systemzustand informiert, so wird dies als Out-of-the-Loop bezeichnet. Zwischen diesen beiden Situationen lassen sich jedoch viele Abstufungen identifizieren, bei denen der Operator nur teilweise involviert und informiert ist.

peripheres Sichtfeld Das periphere Sichtfeld beschreibt den Bereich der visuellen Wahrnehmung, der außerhalb der **Fovea** wahrgenommen wird. Der Bereich, der innerhalb der Fovea wahrgenommen wird, wird **foveales Sichtfeld** genannt.

Priorität Priorität von Aufgaben: s. **Aufgabenpriorität**.

Proportionalglied Ein Proportionalglied ist eine Komponente, die in vielen Reglern verwendet wird. Es verstärkt das Eingangssignal $e(t)$ um einen konstanten Faktor K : $u(t) = K \cdot e(t)$.

Proxy Eine Proxy-Variable beschreibt eine objektiv messbare Größe, die als Stellvertreter für eine nicht direkt messbare Größe steht. In den Experimenten dieser Arbeit wird beispielsweise das Ziel einer Blickfixation als Proxy für den Fokus der mentalen Aufmerksamkeit verwendet.

prozentuale Blickverweilzeit Die prozentuale Blickverweilzeit (engl.: Percentage Dwell Time (PDT)) gibt für eine Informationsquelle den Zeitanteil innerhalb eines definierten Zeitraums an, für den der Blick auf diese Informationsquelle gerichtet ist.

präattentives Merkmal Präattentive Merkmale werden automatisch, unbewusst, parallel und ohne mentalen Aufwand wahrgenommen. Typische Beispiele für präattentive Merkmale sind Farbunterschiede und Bewegungen.

Punktnotation Die Punktnotation wird üblicherweise in der Informatik genutzt, um Attribute eines Objektes zu adressieren. Der Punkt trennt dabei den Objektidentifizierer vom Attributnamen (*Objekt.Name*). Im Kontext dieser Arbeit wird die Punktnotation verwendet, um Pfade im semantischen Netz des Gedächtnisses von CASCaS zu beschreiben. Der Pfad wird ausgehend von einem Startelement über die Beschriftung aller Kanten definiert. Kantenbeschriftungen werden durch einen Punkt getrennt.

punktweise Konvergenz Die punktweise Konvergenz einer Funktionenfolge f_n sagt aus, dass jeder Funktionswert $f_n(x)$ für $n \rightarrow \infty$ gegen den Funktionswert $f(x)$ der Grenzfunktion f konvergiert (Weisstein, 2013b).

Queueing-Modell Mit der Queueing-Theorie (oder Warteschlangentheorie) lassen sich System beschreiben und analysieren, bei denen einer oder mehrere Prozesse Anforderungen stellen, die von einem oder mehreren Service-Points bearbeitet werden (Sen, 2010). Durch die Wartezeiten, die an den Service-Points entstehen, kann die Dynamik eines solchen Systems sehr komplex werden. Das menschliche Blickverhalten lässt sich auch als Queueing-Modell beschreiben, bei dem der Blickfokus der einzige Service-Point. Er erhält Anforderungen von mehreren Informationsquellen.

Randstreifen Im Straßenbau ist der Randstreifen der schmale, befestigte Teil einer Straße zwischen der äußersten Fahrbahnrandmarkierung und dem Ende der befestigten Straße. Wie im Szenario, das in dieser Arbeit untersucht wurde, ist dies außerorts typischerweise der Übergang zum Grünstreifen des Banketts. Die Breite des Randstreifens wird durch die Richtlinien für die Anlage von Straßen (Forschungsgesellschaft für Straßen- und Verkehrswesen, 1996b) definiert.

Regelabweichung In der Regelungstechnik stellt die Regelabweichung die Differenz zwischen der Regel- und der Führungsgröße dar — also zwischen Ist- und Sollzustand.

Root-Mean-Square Deviation Die Wurzel der mittleren quadratischen Abweichung (Root-Mean-Square Deviation oder kurz RMSD) ist ein Maß, um die Residuen zwischen beobachteten Daten X_{obs} und den durch ein Modell vorhergesagten Daten X_{model} zu beschreiben. Es wird für n Messpunkte wie folgt bestimmt:

$$RMSD = \sqrt{\frac{\sum_{i=1}^n (X_{obs,i} - X_{model,i})^2}{n}}$$

Sakkade Als Sakkade wird die schnelle Augenbewegung zwischen zwei Fixationen bezeichnet ($\hat{=}$ *saccade* in ISO 15007-1:2002 (ISO, 2002)).

Sinusoid Ein Sinusoid ist eine Funktion der Form $f(x) = a \cdot \sin(\omega x + c)$. Sie ergibt sich aus der Sinusfunktion durch eine Skalierung der Amplitude um a , Skalierung der Frequenz um ω und einer Phasenverschiebung von c (Weisstein, 2013a)..

Skill In der kognitiven Architektur CASCaS werden Modelle von stark trainierten, fertigkeitbasierten Bewegungsabläufen auf der autonomen Ebene als Skills bezeichnet (s. Abschnitt 2.3.6).

Stellgröße In der Regelungstechnik ist die Stellgröße der Wert, der durch den Regler bestimmt wird und über den auf die Regelstrecke eingewirkt wird..

Surrogat Als Surrogat werden im Kontext dieser Arbeit Aufgaben bezeichnet, die stellvertretend für konkrete Aufgaben in realen Situationen verwendet werden. Die Interaktion mit diesen Aufgaben ist auf wenige Aspekte beschränkt,

die in der jeweiligen Studie untersucht werden sollen. Senders Aufgabe (Kapitel 4) ist ein Surrogat für eine Überwachungsaufgabe. Der Number Read Back Task (Kapitel 5) dient dagegen als Surrogat für die Interaktion mit einem Fahrzeugsystem.

Tangentenpunkt Eine Tangente ist eine Gerade, die eine Kurve in einem Punkt berührt, aber nicht schneidet. In diesem Punkt haben Gerade und Kurve die gleiche Orientierung. Salvucci und Gray (2004) nutzen den Tangentenpunkt zwischen der äußeren Spurbegrenzung und der Fixationsgeraden als Fernpunkt für die Lateralkontrolle ihres Fahrermodells.

Top-Down-Aufmerksamkeitskontrolle s. endogene Aufmerksamkeitskontrolle.

Transitionswahrscheinlichkeit Die Transitionswahrscheinlichkeit gibt die relative Häufigkeit von Blicktransitionen zwischen zwei Informationsquellen A und B im Verhältnis zur Anzahl aller Blicktransitionen an. Dabei wird nicht unterschieden zwischen Transitionen von A nach B und von B nach A. ($\hat{=}$ *link value probability* in ISO 15007-1:2002 (ISO, 2002)) (siehe auch *gerichtete Transitionswahrscheinlichkeit*).

Transition Als Transition wird die Blickbewegung von einer Informationsquelle zu einer anderen bezeichnet.

visuelle Aufmerksamkeit Der Begriff der visuellen Aufmerksamkeit beschreibt in dieser Arbeit die Informationsquelle, auf die zur Zeit der Fokus des Blicks gerichtet ist (siehe auch *mentale Aufmerksamkeit*).

Z-Transformation Über die Z-Transformation lassen sich unterschiedlich verteilte Zufallsvariablen standardisieren, um sie miteinander vergleichen zu können. Für eine Verteilung mit Mittelwert μ und Standardabweichung σ wird der Z-Wert einer Variablen x bestimmt durch $z = \frac{x-\mu}{\sigma}$ (Bortz und Schuster, 2010, S. 35).

Zielagenda Im Kontext dieser Arbeit wird die Menge aller Aufgabenziele, die ein kognitiver Agent aktuell anstrebt, als Zielagenda bezeichnet.

Zielwarteschlange Die Zielwarteschlange ist eine Struktur in CASCaS die basierend auf Salvucci (2005) vor Einführung des AIE-Modells in der kognitiven Architektur CASCaS verwendet wurde, um die Reihenfolge festzulegen, in der Aufgabenziele zur Bearbeitung ausgewählt werden. Die Reihenfolge wird dabei durch ein einfaches FIFO-Prinzip bestimmt.

Abkürzungsverzeichnis

A ³ I	Aircrew/Aircraft Integration.
A-SA	Attention-Situation Awareness.
ACC	Adaptive Cruise Control.
ACM	Association for Computing Machinery.
ACT-R	Adaptive Control of Thought – Rational.
AIE	Adaptive Information Expectancy.
AOI	Area of Interest.
APEX	Architecture for Procedure Execution.
BAD MoB	Bayesian Autonomous Driver Mixture-of-Behaviors.
BOLD	Blood Oxygenation Level Dependent.
C2C	Car-to-Car.
C2I	Car-to-Infrastructure.
CAD	Computer Aided Design.
CASCaS	Cognitive Architecture for Safety Critical Task Simulation.
COSMODRIVE	Cognitive Simulation Model of the Driver.
CT	Computertomographie.
CTT	ConcurTaskTree.
DARPA	Defense Advanced Research Projects Agency.
DLL	Dynamic Link Library.
EMMA	Eye Movements and Movement of Attention.
EPIC	Executive-Process/Interactive Control.
FIFO	First In, First Out.
fMRT	funktionelle Magnetresonanztomographie.
GOMS	Goals, Operators, Methods and Selection Rules.
HLA	High-Level Architecture.
HTA	Hierarchical Task Analysis.
IMoST	Integrated Modeling for Safe Transportation.

ISi-PADAS	Integrated Human Modeling and Simulation to support Human Error Risk Analysis of Partially Autonomous Driver Assistance Systems.
KLM	Keystroke-Level-Modelling.
LHS	Left Hand Side.
MBUI	Model-Based User Interfaces.
MHP	Model Human Processor.
MIDAS	Man-machine Integration Design and Analysis System.
MRT	Multiple Resource Theory.
N-SEEV	Noticing-SEEV.
NASA	National Aeronautics and Space Administration.
NRBT	Number Read Back Task.
PAAV	Pre-Attentive and Attentive Vision.
PDT	Percentage Dwell Time.
PSM	Periodic Sampling Model.
RCM	Random Constraint Model.
RHS	Right Hand Side.
RMSD	Root-Mean-Square Deviation.
SEEV	Saliency, Effort, Expectancy, Value.
SMRAS	Stochastic Model Reference Adaptive Search.
SSDRIVE	Simple Simulation of Driver Performance.
TLC	Time to Lane Crossing.
UI	User Interface.
VACM	Visual, Auditory, Cognitive, Motoric.
W3C	World Wide Web Consortium.
XML	Extensible Markup Language.

Literaturverzeichnis

Jannes Aasmann. *Modelling Driver Behaviour in SOAR*. Dissertation, Rijksuniversiteit Groningen, 1995.

Bettina Abendroth und Ralph Bruder. Die Leistungsfähigkeit des Menschen für die Fahrzeugführung. In Hermann Winner, Stephan Hakuli, und Gabriele Wolf, Hrsg., *Handbuch Fahrerassistenzsysteme*, Kapitel 1, S. 4–14. Vieweg + Teubner, Wiesbaden, 2009.

ACT–R Tutorial Unit 5. ACT–R 6.0 Tutorial: Unit 5 - activation and context. online, December 2011. URL <http://act-r.psy.cmu.edu/actr6/>. letzter Zugriff: 20.02.2012.

Anupam Agarwal und C. Subramaniam. A comprehensive review of problems associated with long duration flying and some suggested remedies. *Indian Journal of Aerospace Medicine*, 82(2):21–26, 2008.

Aladino Amantini und Pietro Carlo Cacciabue. A simple simulation predicting driver behavior, attitudes and errors. In Vincent G. Duffy, Hrsg., *Digital Human Modelling, HCII 2009*, LNCS 5620, S. 345–354. Springer, Heidelberg, 2009.

J. R. Anderson, D. Bothell, M. D. Byrne, S. Douglass, C. Lebiere, und Y. Qin. An integrated theory of the mind. *Psychological Review*, 111(4):1036–1060, October 2004. ISSN 0033-295X.

John R. Anderson. Using brain imaging to guide the development of a cognitive architecture. In Wayne D. Gray, Hrsg., *Integrated Models of Cognitive Systems*, S. 49–62. Oxford University Press, New York, 2007.

John R. Anderson. *How can the Human Mind Occur in the Physical Universe*. Oxford Series on Cognitive Models and Architectures. Oxford University Press, August 2009.

John R. Anderson. *Learning and Memory: An Integrated Approach*. John Wiley & Sons, New York, 2000. ISBN 0471249254.

John R. Anderson und Christian J. Lebiere. *The Atomic Components of Thought*. Lawrence Erlbaum Associates, June 1998.

John R. Anderson und Lael J. Schooler. Reflections of the environment in memory. *Psychological Science*, 2:396–408, 1991.

John R. Anderson, Lynne M. Reeder, und Christian Lebiere. Working memory: Activation limitations on retrieval. *Cognitive Psychology*, 30:221–256, 1996.

- John R. Anderson, Cameron S. Carter, Jon M. Fincham, Yulin Qin, Susan M. Ravizza, und Miriam Rosenberg-Lee. Using fMRI to test models of complex cognition. *Cognitive Science*, 32:1323–1348, 2008.
- John Annett. Hierarchical task analysis. In Diaper und Stanton (2004), Kapitel 3, S. 67–82.
- John A. Barnes. Analysis of pilot's eye movements during helicopter flight. technical memorandum, Human Engineering Laboratory, U.S. Army Aberdeen Research & Development Center, April 1972.
- Julien Bect, Thierry Bellet, Jean-Charles Bornard, Carlo Cacciabue, Mirella Cassani, Mark Eilers, Dominique Gruyer, Fabio Tango, Emmanuel Vazquez, Bertram Wortelen, und Malte Zilinski. Driver models after phase 2. Technical report, European Project no. 218552, ISI-PADAS, 2011.
- Rachel Bellamy, Bonnie John, und Sandra Kogan. Deploying cogtool: Integrating quantitative usability assessment into real-world software development. In *Proceedings of 33rd International Conference on Software Engineering (ICSE)*, S. 691–700, 2011.
- Thierry Bellet, Béatrice Bailly, Pierre Mayenobe, und Olivier Georgeon. Cognitive modelling and computational simulation of drivers mental activities. In Pietro C. Cacciabue und Cristina Re, Hrsg., *Critical Issues in Advanced Automotive Systems and Human-Centred Design*, S. 317–345. Springer Verlag, London, 2007.
- Thierry Bellet, Jean-Charles Bornard, Pierre Mayenobe, Jean-Christophe Paris, Dominique Gruyer, und Bernard Claverie. Computational simulation of visual distraction effects on car drivers' situation awareness. In Nele Rußwinkel, Uwe Drewitz, und Hedderik van Rijn, Hrsg., *Proceedings of the 11th international Conference on Cognitive Modeling*, S. 59–65, Berlin, 2012. Universitätsverlag der TU Berlin.
- Bruno Berberian, Patrick Le Blaye, Nicolas Maille, und Jean-Christophe Sarrazin. Sense of control in supervision tasks of automated systems. *AerospaceLab*, 4: AL04–09 1–10, May 2012.
- Lu-Zheng Bi und Yi-Li Liu. Modeling driver car-following based on the queuing network cognitive architecture. In *Proceedings of the Eighth International Conference on Machine Learning and Cybernetics*, Badoing, July 2009.
- Jesse Black und John R. Wagner. Vehicle road runoff and return - effect of limited steering intervention. *SAE International Journal of Passenger Cars - Mechanical Systems*, 4(1):523–535, June 2011.
- Peter Blanchonette. Jack human modelling tool: A review. Technical Report DSTO-TR-2364, Australian Defence Science and Technology Organisation, Air Operations Division, Victoria 3207, Australia, January 2010.
- BMW Group. Pressemitteilung - BMW ConnectedDrive 2012. online., July 2012. URL <https://www.press.bmwgroup.com/pressclub/p/pcgl/startpage.htm>. letzter Zugriff: 19.12.2012.

- Erwin R. Boer, Nicholas J. Ward, Michale P. Manser, Tomohiro Yamamura, und Nobuyuki Kuge. Driver performance assessment with a car following model. In *Proceeding of the Third International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design*, S. 433–440, 2005.
- Harrie G. Bohnen, Martinus A. M. Leermakers, und Piet J. Venemans. Sampling behavior in a four instrument monitoring task: Effects of signal bandwidth and number of events per signal. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Human*, 26(4):413–422, July 1996.
- Jean-Charles Bornard, Thierry Bellet, Pierre Mayenobe, Dominique Gruyer, und Bernard Claverie. A perception module for car drivers' visual strategies modeling and visual distraction effect simulation. In *Proceedings of the 1st International Symposium on Digital Human Modeling*, Lyon, France, June 2011.
- Jürgen Bortz und Christof Schuster. *Statistik für Human- und Sozialwissenschaftler*. Springer, 7 edition, 2010.
- Dan Bothell. *ACT-R 6.0 Reference Manual*. Carnegie Mellon University, Department of Psychology, version 1.4 r1307 edition, 20. Dezember 2012. online, <http://act-r.psy.cmu.edu/actr6/reference-manual.pdf>, letzter Zugriff. 28.06.2011.
- Donald Eric Broadbent. *Perception and Communication*. Pergamon Press, 1958.
- Ilja N. Bronstein, K. A. Semendjajew, Gerhard Musiol, und Heiner Muehlig. *Taschenbuch der Mathematik*. Verlag Harri Deutsch, Juli 2008.
- Norman R. Brown. Encoding, representing, and estimating event frequencies: A multiple strategy perspective. In Peter Sedlmeier und Tilmann Betsch, Hrsg., *ETC. Frequency Processing and Cognition*, Kapitel 3, S. 37–53. Oxford University Press, 2002.
- Egon Brunswick. *Perception and the representative design of psychological experiments*. University of California Press, 2nd edition, 1956.
- Claus Bundesen. A theory of visual attention. *Psychological Review*, 97(4):523–547, 1990.
- Michael D. Byrne. Cognitive architecture. In Andrew Sears und Julie A. Jacko, Hrsg., *The Human-Computer Interaction Handbook: Fundamentals, Evolving Technologies and Emerging Applications*, S. 93 – 113. CRC Press, 2nd edition, 2007.
- Michael D. Byrne und John R. Anderson. Perception and action. In John R. Anderson und Christian J. Lebiere, Hrsg., *The Atomic Components of Thought*, Kapitel 6, S. 167–200. Lawrence Erlbaum, 1998.
- Michael D. Byrne und Alex Kirlik. Integrated modeling of cognition and the information environment: A multilevel investigation (process and product modeling) of attention allocation to visual displays. Technical Report AHFD-04-14/NASA-04-4, Aviation Human Factors Division (AHFD), Institute of Aviation, University of Illinois, Urbana-Champaign, Savoy, Illinois 61874, September 2004.

- Pietro Carlo Cacciabue, Cristina Re, und Luigi Macchi. Simple simulation of driver performance for prediction and design analysis. In Pietro Carlo Cacciabue, Hrsg., *Modelling Driver Behaviour in Automotive Environments*, Kapitel 19, S. 344–375. Springer, London, 2007.
- Jamie R. Carbonell. A queuing model of many-instrument visual sampling. *IEEE Transactions on Human Factors in Electronics*, 7(4):157–164, December 1966.
- Jamie R. Carbonell, Jane L. Ward, und John W. Senders. A queuing model of visual sampling: Experimental validation. *IEEE Transactions on Man-Machine Systems*, 9(3):82–87, 1968.
- Stuart K. Card, Thomas P. Moran, und Allen Newell. The keystroke-level model for user performance time with interactive systems. *Communications of the ACM*, 23(7):396–410, July 1980.
- Stuart K. Card, Thomas P. Moran, und Allen Newell. *The Psychology of Human-Computer Interaction*. Erlbaum, Hillsdale, 1983.
- Samuel G. Charlton und John de Pont. Curve speed management. Technical Report Research Report 323, Land Transport New Zealand, 2007.
- Ronald S. Chong und John E. Laird. Identifying dual-task executive process knowledge using EPIC-Soar. In *Proceedings of the Nineteenth Annual Conference of the Cognitive Science Society*, S. 107–112, Hillsdale, NJ, 1997. Erlbaum.
- Continental AG. Pressemitteilung: Maßgeschneiderte Informationen von Zauberkraft: Das Magic User Interface von Continental. online., 19. October 2011. URL http://www.conti-online.com/generator/www/com/de/continental/presseportal/themen/pressemitteilungen/3_automotive_group/interior/press_releases/pr_2011_10_19_magic_user_interface_de.html. letzter Zugriff: 19.12.2012.
- Richard P. Cooper. The role of falsification in the development of cognitive architectures: Insights from a lakatosian analysis. *Cognitive Science*, 31:509–533, 2007.
- Kevin M. Corker und Barry R. Smith. An architecture and model for cognitive engineering simulation analysis: Application to advanced aviation automation. In *Proceedings of AIAA Computing in Aerospace 9 Conference*, San Diego, CA, 21 October 1993.
- David Crookall. Climate change and simulation/gaming: Learning for survival. *Simulation & Gaming*, 44(2-3):195–228, 2013.
- Sidney W.A. Dekker. *Ten Questions about Human Error*. Lawrence Erlbaum Associates, 2005.
- John Derwent und Eric W. Weisstein. Uniform convergence. From *MathWorld* – A Wolfram Web Ressource. online, 2013. URL <http://mathworld.wolfram.com/UniformConvergence.html>. letzter Zugriff: 16.12.2013.
- Robert Desimone und John Duncan. Neural mechanisms of selective visual attention. *Annual Review of Neuroscience*, 18:193–222, 1995.

- Dan Diaper und Neville A. Stanton, Hrsg. *The Handbook of Task Analysis for Human-Computer Interaction*. Lawrence Erlbaum Associates, Inc, Mahwah, New Jersey, 2004.
- Thomas A. Dingus, Sheila G. Klauer, Vicki L. Neale, A. Petersen, S. E. Lee, Jeremy Sudweeks, M. A. Perez, Jonathan M. Hankey, D. Ramsey, S. Gupta, C. Bucher, Z. R. Doerzaph, J. Jermeland, und Ronald R. Knipling. The 100-car naturalistic driving study: Phase II - the 100-car field experiment. Technical report, National Highway Traffic Safety Administration, Washington, DC, 2006. URL <http://www.distraction.gov/research/PDF-Files/The-100-Car-Naturalistic-Driving-Study.pdf>. letzter Zugriff: 05.01.2013.
- Edmund Donges. Fahrerverhaltensmodelle. In Hermann Winner, Stephan Hakuli, und Gabriele Wolf, Hrsg., *Handbuch Fahrerassistenzsysteme*, Kapitel 2, S. 15–23. Vieweg + Teubner, 2009.
- Edmund Donges. A two-level model of driver steering behavior. *Human Factors*, 20(6):691–707, December 1978.
- Mieke Donk. Human monitoring behaviour in multiple-instrument setting: Independent sampling, sequential sampling or arrangement-dependent sampling. *Acta Psychologica*, 86:31 – 55, 1994.
- Shaun Durkee und Nicholas Ward. Effect of driving simulation parameters related to ego-motion on speed perception. In *Proceedings of the Sixth International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design*, S. 358–364, June 2011.
- Mark Eilers und Claus Möbus. Learning the relevant percepts of modular hierarchical bayesian driver models using bayesian information criterion. In Vincent G. Duffy, Hrsg., *Digital Human Modeling, HCII 2011*, Orlando, USA, 2011a.
- Mark Eilers und Claus Möbus. Learning the human longitudinal control behavior with a modular bayesian mixture-of-behaviors model. In *2011 IEEE Intelligent Vehicles Symposium*, S. 540–545, Bade-Baden, Germany, 5-9 June 2011b.
- Mark Eilers und Claus Möbus. Discriminative learning of a probabilistic driver model representing the human driving behavior on virtual highways. In *4. Berliner Fachtagung Fahrermodellierung, Fahrermodelle in Wissenschaft und Wirtschaft*, Berlin, 13.-14. Juni 2013.
- Mark Eilers, Claus Möbus, Olivier Pietquin, und Fabio Tango. The learning of longitudinal human control behaviour and driver assistance strategies. *Transportation Research Part F: Traffic Psychology and Behaviour*, in press, 2013.
- Mica Endsley. Toward a theory of situation awareness in dynamic systems. *Human Factors*, 37(1):32–64, 1995.
- Mica R. Endsley und David B. Kaber. Level of automation effects on performance, situation awareness and workload in a dynamic control task. *Ergonomics*, 42(3): 462–492, 1999.
- Sebastian Engell, Goran Frehse, und Eckehard Schnieder, Hrsg. *Modelling, Analysis and Design of Hybrid Systems*. Lecture Notes in Control and Information Sciences (LNCIS) 279. Springer, 2002.

- K. Anders Ericsson und Herbert A. Simon. *Protocol Analysis: Verbal Reports as Data*. MIT Press, 1993.
- Charles W. Eriksen und James E. Hoffman. The extent of processing of noise elements during selective encoding from visual displays. *Perception & Psychophysics*, 14(1):155–160, 1973.
- William Kaye Estes. Traps in the route to models of memory and decision. *Psychonomic Bulletin & Review*, 9(1):3–25, 2002.
- European Commission. European transport policy for 2010: Time to decide. online., 12. September 2001. URL http://ec.europa.eu/transport/strategies/doc/2001_white_paper/lb_com_2001_0370_en.pdf. letzter Zugriff: 05.01.2013.
- European Commission. Towards a european road safety area: Policy orientations on road safety 2011-2020. online., 20. July 2010. URL http://ec.europa.eu/transport/road_safety/pdf/com_20072010_en.pdf. letzter Zugriff: 05.01.2013.
- Burkhard Fischer. *Blick-Punkte - Neurobiologische Prinzipien des Sehens und der Blicksteuerung*. Hans Huber, Bern, 1999.
- Paul M. Fitts und Charles W. Simon. The arrangement of instruments, the distance between instruments, and the position of instrument pointers as determinants of performance in an eye-hand coordination task. Technical Report USAF-TR-5832, Wright Air Development Center, Air Research Development Command United States Air Force Wright-Patterson Air Force Base, Dayton, Ohio, February 1952. URL <http://www.dtic.mil/dtic/tr/fulltext/u2/a800395.pdf>. letzter Zugriff: 05.01.2013.
- Paul M. Fitts, Richard E. Jones, und John L. Milton. Eye fixations of aircraft pilots III: Frequency, duration and sequence fixations when flying air force ground-controlled approach system (GCA). Technical report, US Air Force, Air Materiel Command, Wright-Patterson Air Force Base, Dayton, Ohio, November 1949.
- Paul M. Fitts, Richard E. Jones, und John L. Milton. Eye movements of aircraft pilots during instrument-landing approaches. *Aeronautical Engineering Review*, 9(2):24–29, 1950.
- Paul Morris Fitts und Michale I. Posner. *Human Performance*. Basic Concepts in Psychology. Prentice-Hall, 1973.
- Michael D. Fleetwood. *Refining Theoretical Models of Visual Sampling in Supervisory Control Tasks: Examining the Influence of Alarm Frequency, Effort, Value, and Salience*. Dissertation, Rice University, Houston, Texas, May 2005.
- Forschungsgesellschaft für Straßen- und Verkehrswesen. Richtlinien für die Anlage von Straßen: Linienführung. Technical Report 296, FGSV-Verlag, 1996a. Berichtigter Nachdruck 1999.
- Forschungsgesellschaft für Straßen- und Verkehrswesen. Richtlinien für die Anlage von Straßen: Querschnitt. Technical Report 295, FGSV-Verlag, 1996b.
- Michael Alan Freed. *Simulating Human Performance in Complex, Dynamic Environments*. Dissertation, Northwestern University, Evanston, Illinois, June 1998.

- Edward G Freedman. Interactions between eye and head control signals can account for movement kinematics. *Biological Cybernetics*, 84(6):453–462, 2001.
- Raymond Freymann. Möglichkeiten und grenzen von fahrerassistenz- und aktiven sicherheitssystemen. In *1. Tagung Aktive Sicherheit durch Fahrerassistenz*, 2004.
- Florian Frische, Jan-Patrick Osterloh, und Andreas Lüdtke. Modelling and validating pilots visual attention allocation during the interaction with an advanced flight management system. In *Proceedings of Human Modelling in Assisted Transportation (HMAT)*, S. 165–172. Springer, August 2010.
- Danilo Fum, Fabio Del Missier, und Andrea Stocco. The cognitive modeling of human behavior: Why a model is (sometimes) better than 10,000 words. *Cognitive Systems Research*, 8:135–142, 2007.
- William J Gehring, Richard L. Bryck, John Jonides, Roger L. Albin, und David Badre. The mind’s eye, looking inward? In search of executive control in internal attention shifting. *Psychophysiology*, 40:572–585, 2003.
- Brian F. Gore, Becky L. Hoey, Christopher D. Wickens, und Shelly Scott-Nash. A computational implementation of a human attention guiding mechanism in midas v5. In Vincent G. Duffy, Hrsg., *Digital Human Modeling*, volume 5620/2009 of *Lecture Notes in Computer Science*, S. 237–246. Springer, Berlin, 2009.
- Brian F. Gore, Becky L. Hoey, Christopher D. Wickens, Connie Socash, Mala Gosakan, Marc Gacy, Mark Brehon, und David C. Foyle. Workload as a performance shaping factor in MIDAS v5. Proceedings of the Behavioral Representation in Modeling and Simulation (BRIMS) 2011 Conference, 26 March 2011.
- Birgit Graab, Eckart Donner, Ulrich Chiellino, und Maria Hoppe. Analyse von Verkehrsunfällen hinsichtlich unterschiedlicher Fahrerpopulationen und daraus ableitbarer Ergebnisse für die Entwicklung adaptiver Fahrerassistenzsysteme. In *Tagung aktive Sicherheit 2008*. Technische Universität München, 7. April 2008.
- Tovi Grossman und Ravin Balakrishnan. Pointing at trivariate targets in 3d environments. In Elizabeth Dykstra-Erickson und Manfred Tscheligi, Hrsg., *Proceedings of the International Conference on Human Factors in Computing Systems (CHI)*, S. 447–454, Vienna, Austria, 24-29 April 2004. ACM.
- The Eyesight Working Group. New standards for the visual functions of drivers. Technical report, Europäische Kommission, Brüssel, Mai 2005. URL http://ec.europa.eu/transport/road_safety/behavior/doc/new_standards_final_version_en.pdf. letzter Zugriff: 05.01.2013.
- Kerstin Sophie Haring, Marco Ragni, und Lars Konieczny. A cognitive model of drivers attention. In *Proceedings of the 11th International Conference on Cognitive Modeling*. Universitätsverlag der TU Berlin, 2012.
- John M. Henderson und Andrew Hollingworth. Eye movements during scene viewing: An overview. In Geoffrey Underwood, Hrsg., *Eye Guidance in Reading and Scene Perception*, Kapitel 12, S. 269–294. Elsevier Science, 1998.
- Ellen C. Hildreth, Jack M. Beusmans, Erwin R. Boer, und Constance S. Royden. From vision to action: Experiments and models of steering control. *Journal of Experimental Psychology: Human Perception and Performance*, 26(3):1106–1132, Juni 2000.

- Robin M. Hogarth und Hillel J. Einhorn. Order effects in belief updating: The belief-adjustment model. *Cognitive Psychology*, 24(1):1–55, January 1992.
- Sture Holm. A simple sequentially rejective multiple test procedure. *Scandinavian Journal of Statistics*, 6(2):65–70, 1979.
- William J. Horrey und Christopher D. Wickens. Focal and ambient visual contributions and driver visual scanning in lane keeping and hazard detection. In *Proceedings of the Human Factors and Ergonomics Society 48th annual meeting*, 2004.
- William J. Horrey, Christopher D. Wickens, und Kyle P. Consalus. The distracted driver: Modeling the impact of information bandwidth, in-vehicle task priority, and spatial-separation on driver performance and attention allocation. Technical Report AHFD-05-11/GM-05-2, General Motors Corporation, Warren, MI, August 2005.
- William J. Horrey, Christopher D. Wickens, und Kyle P. Consalus. Modeling drivers' visual attention allocation while interacting with in-vehicle technologies. *J. Exp. Psychol.-Appl.*, 12(2):67–78, 2006.
- Jiaqiao Hu, Michael C. Fu, und Steven I. Marcus. A model reference adaptive search method for stochastic global optimization. *Communications in Information and Systems*, 8(3):245–276, 2008.
- Country & Industry Forecasting IHS Global Insight. Vehicle connectivity and automation to increase rapidly; car-to-car communications field test begins. online., 14. August 2012. URL <http://www.ihs.com/products/global-insight/industry-economic-report.aspx?id=1065970540>. Letzter Zugriff 05.08.2013.
- ISO. *ISO 15007-1:2002. Part 1: Road Vehicles: Measurement of Driver Visual Behaviour with Respect to Transport Information and Control Systems – Definitions and Parameters*. ISO, Genf, Schweiz, 2002. Stage 90.92.
- ISO. *ISO 15007-2:2001. Part 2: Road Vehicles: Measurement of Driver Visual Behaviour with Respect to Transport Information and Control Systems – Equipment and Procedures*. ISO, Genf, Schweiz, 2001.
- Laurent Itti und Christof Koch. Computational modelling of visual attention. *Nature Reviews Neuroscience*, 2(3):194–203, Mar 2001. URL http://iLab.usc.edu/publications/doc/Itti_Koch01nrrn.pdf.
- Robert G. Jaeger und Tim R. Halliday. On confirmatory versus exploratory research. *Herpetologica*, 54(Suppl.):64–66, 1998.
- William James. *The Principles of Psychology*, volume 1. Holt and Macmillan, 1890.
- Qiang Ji, Zhiwei Zhu, und Peilin Lan. Real-time nonintrusive monitoring and prediction of driver fatigue. *IEEE Transactions on Vehicular Technology*, 53(4):1052–1068, July 2004.
- Bonnie E. John. Using predictive human performance models to inspire and support ui design recommendations. In *Proceedings of the 2011 Annual Conference on Human Factors in Computing Systems*, CHI '11, S. 983–986, New York, NY, USA, 2011. ACM. ISBN 978-1-4503-0228-9.

- Bonnie E. John und Dario D. Salvucci. Multipurpose prototypes for assessing user interfaces in pervasive computing systems. *IEEE Pervasive Computing*, 4(4): 27–34, 2005.
- Bonnie E. John, Konstantine Prevas, Dario D. Salvucci, und Ken Koedinger. Predictive human performance modeling made easy. In *Proceedings of CHI*, volume 6, S. 455–462, Vienny, Austria, 24.-29. April 2004.
- Bonnie E. John, Sonal M. Starr, und Brian S. Utesch. Experiences with collaborative, distributed predictive human performance modeling. In *CHI '12 Extended Abstracts on Human Factors in Computing Systems*, S. 437–452, New York, NY, USA, 2012. ACM.
- Sheree Josephson. A summary of eye-movement methodologies. online., 2004. URL http://www.factone.com/article_2.html. letzter Zugriff: 08.07.2010.
- Marcel Adam Just und Patricia A. Carpenter. Eye fixations and cognitive processes. *Cognitive Psychology*, 8:441–480, 1976.
- Marcel Adam Just und Patricia A. Carpenter. A theory of reading: From eye fixations to comprehension. *Psychological Review*, 87(4):329–354, July 1980.
- Daniel Kahneman. *Attention and Effort*. Prentice-Hall, Englewood Cliffs, New Jersey, 1973.
- Farid I. Kandil, Alexander Rotter, und Markus Lappe. Driving is smoother and more stable when using the tangent point. *Vision*, 9(1):1–11, January 2009.
- David Kieras. Goms models for task analysis. In Dan Diaper und Neville Stanton, Hrsg., *The Handbook of Task Analysis for Human-Computer Interaction*, Kapitel 4, S. 83–116. Lawrence Erlbaum Associates, 2004.
- David E. Kieras und David E. Meyer. An overview of the EPIC architecture for cognition and performance with application to human-computer interaction. *Human-Computer interaction*, 12:391–438, 1997.
- David E. Kieras und David E. Meyer. The role of cognitive task analysis in the application of predictive models of human performance. In Jan Maarten Schraagen, Susan F. Chipman, und Valerie L. Shalin, Hrsg., *Cognitive Task Analysis*, Kapitel 15, S. 237–259. Lawrence Erlbaum Associates, March 2000.
- Davied E. Kieras. The control of cognition. In Wayne D. Gray, Hrsg., *Integrated Models of Cognitive Systems*, Kapitel 23. Oxford University Press, New York, 2007.
- Jan H. G. Klabbers. A framework for artifact assessment and theory testing. *Simulation & Gaming*, 37(2):155–173, 2006.
- Sheila G. Klauer, Thomas A. Dingus, Vicki L. Neale, Jeremy Sudweeks, und D. Ramsey. The impact of driver inattention on near-crash/crash risk: An analysis using the 100-car naturalistic driving study data. Technical report, Virginia Tech Transportation Institute, Blacksburg, Virginia, April 2006. Report No.: DOT HS 810594.

- Sheila G. Klauer, Feng Guo, Jeremy Sudweeks, und Thomas A. Dingus. An analysis of driver inattention using a case-crossover approach on 100-car data: Final report. Technical report, Virginia Tech Transportation Institute, Blacksburg, Virginia, Mai 2010. Report No.: DOT HS 811334.
- Ronald R. Knippling. IVHS technologies applied to collision avoidance: Perspectives on six target crash types and countermeasures. In *the Proceedings of the 1993 IVHS America Annual Meeting, Washington, DC.*, 1993.
- Christof Koch und Shimon Ullmann. Shifts in selective visual attention: Towards the underlying neural circuitry. *Human Neurobiology*, 4(4):219–227, 1985.
- Aachal Kotecha, Alexander Spratt, und Ananth Viswanathan. Visual function and fitness to drive. *British Medical Bulletin*, 87:163–174, 2008.
- Jarek Krajewski, David Sommer, Udo Trutschel, Dave Edwards, und Martin Golz. Steering wheel behavior based estimation of fatigue. In *Proceedings of the Fifth International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design*, 2009.
- Jogn E. Laird. *The Soar Tutorial: Updated for Soar 9.0.0*, 27. August 2008. URL <http://sitemaker.umich.edu/soar>.
- John E. Laird. *The Soar Cognitive Architecture*. MIT Press, 2012.
- John E. Laird und Robert E. Wray. Cognitive architecture requirements for achieving AGI. In *Proceedings of the Third Conference on Artificial General Intelligence (AGI)*, 2010.
- John E. Laird, Allen Newell, und Paul S. Rosenbloom. Soar: An architecture for general intelligence. *Artificial Intelligence*, 33(1):1–64, 1987.
- John E. Laird, Clare Bates Congdon, Karen J. Coulter, Nate Derbinsky, und Joseph Xu. The soar user’s manual version 9.3.2. online, April 2012. URL <http://web.eecs.umich.edu/~soar/downloads/Documentation/SoarManual.pdf>.
- Imre Lakatos. Falsification and the methodology of scientific research programs. In Imre Lakatos und Alan Musgrave, Hrsg., *Criticism and the Growth of Knowledge*, S. 91–195. Cambridge University Press, Cambridge, UK, 1970.
- Michael F. Land und Julia Horwood. Which parts of the road guide steering? *Nature*, 377:339–340, September 1995.
- Michael F. Land und David N. Lee. Where we look when we steer. *Nature*, 369: 742–744, June 1994.
- Michael F. Land und Benjamin W. Tatler. *Looking and Acting: Vision and Eye Movements in Natural Behaviour*. Oxford University Press, New York, 2009.
- Peter C. R. Lane und Fernand Gobet. A theory-driven testing methodology for developing scientific software. *Journal of Experimental & Theoretical Artificial Intelligence*, 24(4):421–456, 2012. accepted for publication.
- Pat Langley, John E. Laird, und Seth Rogers. Cognitive architectures: Research issues and challenges. *Cognitive Systems Research*, 10(2):141–160, 2009.

- Scott D. Lathrop und John E. Laird. Towards incorporating visual imagery into a cognitive architecture. In *Proceedings of the Eighth International Conference on Cognitive Modeling*, S. 25–30. Taylor & Francis/Psychology Press, 2007.
- Andreas Lüdtke. *Kognitive Analyse formaler sicherheitskritischer Systeme auf Basis eines integrierten Mensch-Maschine-Modells*. Dissertation, Universität Oldenburg, 2005.
- Andreas Lüdtke und Jan-Patrick Osterloh. Simulating perceptive processes of pilots to support system design. In Tom Gross, Jan Gulliksen, Paula Kotzé, Lars Oestreicher, Philippe Palanque, Raquel Oliveira Prates, und Marco Winckler, Hrsg., *Human-computer interaction - INTERACT 2009: 12th IFIP TC 13 International Conference*, S. 471–412, Berlin Heidelberg, 2009. Springer.
- Andreas Lüdtke und Jan-Patrick Osterloh. Modeling memory effects in the operation of advanced flight management systems. In *Proceedings of the 2010 HCI-Aero conference*, Cape Canaveral, USA, 2010.
- Andreas Lüdtke, Jan-Patrick Osterloh, Lars Weber, und Bertram Wortelen. Modeling pilot and driver behavior for human error simulation. In Vincent G. Duffy, Hrsg., *Digital Human Modeling*, volume 5620/2009 of *Lecture Notes in Computer Science*, S. 403–412. Springer, Berlin, 2009.
- Andreas Lüdtke, Denis Javaux, und The HUMAN Consortium. The HUMAN project: Model-based analysis of human errors during aircraft cockpit system design. In Pietro Carlo Cacciabue, Magnus Hjälmdahl, Andreas Lüdtke, und Costanza Riccioli, Hrsg., *Human Modelling in Assisted Transportation: Models, Tools and Risk Methods*, S. 79–95, Milano, 2011. Springer Italia.
- Nevada Legislature. Committee on transportation. assembly bill no. 511. online., 16. June 2012. URL <http://www.leg.state.nv.us/Session/76th2011/reports/history.cfm?ID=1011>. letzter Zugriff: 19.12.2012.
- Jill Fain Lehman, John Laird, und Paul Rosenbloom. A gentle introduction to soar, an architecture for human cognition: 2006 update. online., 2006. URL <http://ai.eecs.umich.edu/soar/sitemaker/docs/misc/GentleIntroduction-2006.pdf>. letzter Zugriff: 01.07.2011.
- John K. Lenneman, Joseph Lenneman, Nicholas Cassavaugh, und Richard Backs. Differential effects of focal and ambient visual processing demands on driving performance. In *Proceedings of the Fifth International Driving Symposium on Human Factors in Driver Assessment, Training and Vehicle Design*, S. 306–312, 2009.
- Nancy G. Leveson. *Engineering a Safer World*. MIT Press, January 2011.
- Geoffrey R. Loftus, Leah Kaufman, Takehiko Nishimoto, und Eric Ruthruff. Effects of visual degradation on eye-fixation duration, perceptual processing, and long-term visual memory. In Keith Rayner, Hrsg., *Eye Movements and Visual Cognition: Scene Perception and Reading*, S. 203–226. Springer, 1992.
- R. Duncan Luce. *Individual Choice Behavior*. Wiley, New York, 1959.
- Chris Löwer und Gordon Bolduan. Smartphone auf Rädern. *Technology Review*, 01.2011:48–51, Januar 2011.

- Xiaoliang Ma und Ingmar Andréasson. Estimation of driver reaction time from car-following data: Application in evaluation of general motor-type model. *Transportation Research Record*, 1:130–141, 2006.
- Charles C. MacAdam. Development of a driver model for near/at-limit vehicle handling. Technical report, University of Michigan, Transportation Research Institute, 290 1 Baxter Road, Ann Arbor, Michigan, December 2001. URL <http://deepblue.lib.umich.edu/bitstream/2027.42/1485/2/95569.0001.001.pdf>. letzter Zugriff: 05.01.2013.
- Charles C. MacAdam. Understanding and modeling the human driver. *Vehicle System Dynamics*, 40:101–134, 2003.
- David J. C. MacKay. Model comparison and occam’s razor. In *Information Theory, Inference, and Learning Algorithms*, S. 343–356. Cambridge University Press, 4 edition, 2005.
- Matei Mancas, Laurent Couvreur, Bernard Gosselin, und Benoît Macq. Computational attention for event detection. In *5th International Conference on Computer Vision Systems*, Bielefeld, 2007. URL <http://biacoll.uni-bielefeld.de/volltexte/2007/79>.
- Anu Maria. Introduction to modelling and simulation. In Sigrún Andradóttir, Kevin J. Healy, David H. Withers, und Barry L. Nelson, Hrsg., *Proceedings of the 1997 Winter Simulation Conference*, S. 7–13, 1997.
- Claus Möbus und Mark Eilers. Mixture of behaviors and levels-of-expertise in a bayesian autonomous driver model. In Vincent G. Duffy, Hrsg., *Advances in Applied Digital Human Modeling*, S. 425–435. CRC Press, Boca Raton,, 2010.
- Claus Möbus, Mark Eilers, Hilke Garbe, und Malte Zilinski. Probabilistic and empirical grounded modeling of agents in (partial) cooperative traffic scenario. In Vincent G. Duffy, Hrsg., *Digital Human Modeling, HCII 2009*, volume LNCS 5620, S. 423–432. Springer, 2009.
- Claus Möbus, Mark Eilers, und Hilke Garbe. Predicting the focus of attention and deficits in situation awareness with a modular hierarchical bayesian driver model. In *Digital Human Modeling - Third International Conference, ICDHM 2011, Held as Part of HCI International 2011*, LNCS 6777, S. 483–492, Orlando, FL, USA, 2011a. Springer.
- Claus Möbus, Jan Charles Lenk, Jale Özyurt, Christiane M. Thiel, und Arno Claassen. Checking the ACT-R/brain mapping hypothesis with a complex task: Using fMRI and bayesian identification in a multi-dimensional strategy space. *Cognitive Systems Research*, 12(3-4):321–335, September 2011b. Special Issue on Complex Cognition.
- Jason S. McCarley, Christopher D. Wickens, Juliana Goh, und William J. Horrey. A computational model of attention/situation awareness. In *Proceedings of the 46th Annual Meeting of the Human Factors and Ergonomics Society*, 2002.
- A. James McKnight und Bert B. Adams. Driver education task analysis, Vol.1: Task descriptions. Technical report, Human Resources Research Organization, 1970.

- John A. Michon. A critical view of driver behavior models: What do we know, what should we do? a critical view of driver behaviour models: What do we know, what should we know? In Leonard Evans und Richard C. Schwing, Hrsg., *Human Behavior and Traffic Safety*, S. 485–520. Plenum Press, 1985.
- George A. Miller. The magical number seven, plus or minus two: some limits on our capacity for processing information. *Psychological Review*, 63(2):81–97, March 1956.
- Robert B. Miller. A method for man-machine task analysis. Technical report, Wright Air Development Center, June 1953. URL <http://www.dtic.mil/dtic/tr/fulltext/u2/015921.pdf>. letzter Zugriff: 05.01.2013.
- Sarah Miller, Alex Kirlik, Alex Kosorukoff, und Michael D. Byrne. Ecological validity as a mediator of visual attention allocation in human-machine systems. Technical Report AHFD-04-17/NASA-04-6, NASA Ames Research Centre, Moffett Field, CA, December 2004.
- Sarah M. Miller und Wai-Tat Fu. The role of temporal sequence learning in guiding visual attention allocation. In *Proceedings of the Human Factors and Ergonomics Society 51st Annual Meeting*, S. 1368–1372, 2007.
- Neville Moray. Monitoring behavior and supervisory control. In Kenneth R. Boff, Lloyd Kaufman, und James P. Thomas, Hrsg., *Handbook of Perception and Human Performance. Volume 2. Cognitive Processes and Performance*, Kapitel 40, S. 40–1 – 40–51. Wiley-Interscience, November 1986.
- Brendan Morris, Anup Doshi, und Mohan Trivedi. Lane change intent prediction for driver assistance: On-road design and evaluation. In *2011 IEEE Intelligent Vehicles Symposium*, S. 895–901, Baden-Baden, 5-9 Juni 2011.
- Hendrik Neumann und Barbara Deml. The two-point visual control model of steering - new empirical evidence. In Vincent G. Duffy, Hrsg., *Digital Human Modeling, HCII 2011*, LNCS 6777, S. 493–502. Springer-Verlag Berlin Heidelberg, 2011.
- Allen Newell. You can't play 20 questions with nature and win. In William G. Chase, Hrsg., *Visual Information Processing*, S. 283–308. Academic Press, New York, 1973.
- Allen Newell. *Unified Theories of Cognition*. Harvard University Press, Cambridge, MA, 1990.
- Allen Newell und Herbert A. Simon. The logic theory machine: A complex information processing system. Technical report, The Rand Corporation, Santa Monica, CA, June 1956.
- Allen Newell und Herbert A. Simon. GPS, a program that simulates human thought. In Heinz Billing, Hrsg., *Lernende Automaten*, S. 109–124. Oldenbourg, München, 1961.
- Enkhbold Nyamsuren und Niels A. Taatgen. Pre-attentive and attentive vision module. *Cognitive System Research*, 24:62–71, September 2013.

- Andrew M.C. Odhams und David J. Cole. Models of driver speed choice in curves. In *7th International Symposium on Advanced Vehicle Control (AVEC 04)*, S. 439–444, Arnheim, Niederlande, August 2004.
- Thomas C. Ormerod und Andrew Sheperd. Using task analysis for information requirements specification: The SGT method. In *Diaper und Stanton (2004)*, Kapitel 17, S. 347–365.
- Saskia Ossen und Serge P. Hoogendoorn. Heterogeneity in car-following behavior: Theory and empirics. *Transportation Research Part C*, 19(4):182–195, August 2011.
- Jan-Patrick Osterloh und Andreas Lüdtkke. Analyzing the ergonomics of aircraft cockpits using cognitive models. In Waldemar Karwowski und Gabriel Salvendy, Hrsg., *Proceedings of the 2nd International Conference on Applied Human Factors and Ergonomics (AHFE)*, Las Vegas, Nevada, USA, July 2008.
- Jan-Patrick Osterloh, Rene Feil, Andreas Lüdtkke, und Juan Gonzalez-Calleros. Automated ui evaluation based on a cognitive architecture and usixml. In A. Coyette, D. Faure, J. Gonzalez, und J. Vanderdonckt, Hrsg., *Proc. of Int. Workshop on User Interface Description Language UIDL 2011*. Thales Research and Technology France, Paris, 6th September 2011.
- Jan-Patrick Osterloh, Stefan Puch, Martin Fränze, und Christoph Läsche. Rapid virtual-human-in-the-loop simulation with the high level architecture. In *Proceedings of the Summer Computer Simulation Conference 2012*, volume 44 of *Simulation Series*, S. 44–50, Genoa, Italy, 2012. Curran Associates, Inc.
- Francesco Panerai, Jacques Droulez, Jean Marc Kelada, Andras Kemeny, E. Baligand, und B. Favre. Speed and safety distance control in truck driving: comparison of simulation and real-world environment. In *Proceedings of the Driving Simulation Conference 2001*, Nice, France, 2001.
- Sakda Panwai und Hussein Dia. Comparative evaluation of microscopic car-following behavior. *IEEE Transactions on Intelligent Transportation Systems*, 6(3):314–325, 2005.
- Raja Parasuraman und Victor Riley. Humans and automation: Use, misuse, disuse and abuse. *Human Factors*, 39(2):230–253, 1997.
- Derrick Parkhurst, Klinton Law, und Ernst Niebur. Modeling the role of salience in the allocation of overt visual attention. *Vision Research*, 42:107–123, 2002.
- Fabio Paternò. Concurtasktrees: An engineered notation for task models. In Dan Diaper und Neville Stanton, Hrsg., *The Handbook of Task Analysis for Human-Computer Interaction*. Lawrence Erlbaum Associates, Mahwah, 2004.
- Fabio Paternò, Carmen Santoro, Lucio Davide Spano, und Dave Raggett. Mbui - task models. online, 2. August 2012. URL <http://www.w3.org/TR/2012/WD-task-models-20120802/>. letzter Zugriff: 10.10.2013.
- Cameron R. Peterson und Lee Roy Beach. Man as an intuitive statistician. *Psychological Bulletin*, 68(1):29–46, 1967.

- Mark A. Pitt, Woojae Kim, Daniel J. Navarro, und Jay I. Myung. Global model analysis by parameter space partitioning. *Psychological Review*, 13(1):57–83, 2006.
- William H. Press, Saul A. Teukolsky, William T. Vetterling, und Brian P. Flannery. *Numerical Recipes in C: The Art of Scientific Computing*. Cambridge University Press, 1992.
- Paolo Pretto und Astros Chatziastros. Changes in optic flow and scene contrast affect the driving speed. In *Driving Simulation Conference Europe (DSC Europe 2006)*, S. 263 – 272, Arcueil, France, 2006. Institut National de Recherche sur les Transports et Leur Sécurité.
- Jens Rasmussen. Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. *IEEE Transactions on Systems, Man and Cybernetics*, 13(3):257–266, 1983. URL http://www.cs.toronto.edu/~nearnst/papers/Rasmussen_-_SRK.pdf.
- Fred W. Rauskolb, Kai Berger, Christian Lipski, Marcus A. Magnor, Karsten Cornelien, Jan Effertz, Thomas Form, Fabian Graefe, Sebastian Ohl, Walter Schumacher, Jörn-Marten Wille, Peter Hecker, Tobias Nothdurft, Michael Doering, Kai Homeier, Johannes Morgenroth, Lars C. Wolf, Christian Basarke, Christian Berger, Tim Gülke, Felix Klose, und Bernhard Rumpe. Caroline: An autonomously driving vehicle for urban environments. *Journal of Field Robotics*, 25(9): 672–724, 2008.
- Keith Rayner. Eye movements in reading and information processing: 20 years of research. *Psychological Bulletin*, 124(3):372–422, 1998.
- Erik D. Reichle, Alexander Pollatsek, Donald L. Fisher, und Keith Rayner. Toward a model of eye movement control in reading. *Psychological Review*, 105(1):125–157, 1998.
- Gilles Reymond, Andras Kemeny, Jacques Droulez, und Alain Berthoz. Role of lateral acceleration in curve driving: driver model and experiments on a real vehicle and a driving simulator. *Human Factors*, 43(3):483–495, 2001.
- Juliet Richardson, Thomas C. Ormerod, und Andrew Shepherd. The role of task analysis in capturing requirements for interface design. *Interacting with Computers*, 9:367–384, 1998.
- Frank E. Ritter und Richard M. Young. Embodied models as simulated users: Introduction to this special issue on using cognitive models to improve interface design. *International Journal of Human-Computer Studies*, 55:1–14, 2001.
- Frank E. Ritter, Gordon D. Baxter, Gary Jones, und Richard M. Young. Supporting cognitive models as users. *ACM Transactions on Computer-Human Interaction*, 7(2):141–173, June 2000.
- Giacomo Rizzolatti, Lucia Riggio, und Boris M. Shelig. Space and selective attention: Conscious and nonconscious information processing. In Carlo Umiltà und Morris Moscovitch, Hrsg., *Attention and Performance XV*, Kapitel 9, S. 231–265. MIT Press, August 1994.
- Seth Roberts und Harold Pashler. How persuasive is a good fit? A comment on theory testing. *Psychological Review*, 107:358–367, January 2000.

- Mikko Räsänen und Heikki Summala. Attention and expectation problems in bicycle-car collisions: An in-depth study. *Accident Analysis and Prevention*, 30(5):657–666, 1998.
- J. Edward Russo, Eric J. Johnson, und Debra L. Stephens. The validity of verbal protocols. *Memory & Cognition*, 17(6):759–769, 1989.
- Dario D. Salvucci. An integrated model of eye movements and visual encoding. *Journal of Cognitive Systems Research*, 1(4):201–220, 2001a.
- Dario D. Salvucci. Predicting the effects of in-car interface use on driver performance: An integrated approach. *Human-Computer Studies*, 55:85–107, 2001b.
- Dario D. Salvucci. A multitasking general executive for compound continuous tasks. *Cognitive Science*, 29:457–492, 2005.
- Dario D. Salvucci. Rapid prototyping and evaluation of in-vehicle interfaces. *ACM Transactions on Computer-Human Interaction*, 16(2):9:1–9:33, Juni 2009.
- Dario D. Salvucci. *Mapping eye movements to cognitive processes*. Dissertation, Carnegie Mellon University, Pittsburgh, PA, USA, 1999. Chair-Anderson, John R.
- Dario D. Salvucci. Modeling driver behavior in a cognitive architecture. *Human Factors*, 48:362–380, 2006.
- Dario D. Salvucci und Joseph H. Goldberg. Identifying fixations and saccades in eye-tracking protocols. In *Proceedings of the Eye Tracking Research and Applications Symposium*, S. 71–78, New York, 2000. ACM Press.
- Dario D. Salvucci und Rob Gray. A two-point visual control model of steering. *Perception*, 33(10):1233 – 1248, 2004.
- Dario D. Salvucci und Frank J. Lee. Simple cognitive modeling in a complex cognitive architecture. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems: CHI 2003*, S. 265–272, New York, 2003. ACM Press.
- Dario D. Salvucci und Niels A. Taatgen. *The Multitasking Mind*. Oxford Series on Cognitive Models and Architectures. Oxford University Press, 2011.
- Robert G. Sargent. Verification and validation of simulation models. In Michael E. Kuhl, Natalie M. Steiger, F. Brad Armstrong, und Jeffrey A. Joines, Hrsg., *Proceedings of the 37th Winter Simulation Conference*, S. 130–143, Orlando, FL, USA, Dezember 4-7 2005.
- Nadine Sarter. Multiple-resource-theory as a basis for multimodal interface design: Success stories, qualification and research needs. In Arthur F. Kramer, Douglas A. Wiegmann, und Alex Kirlik, Hrsg., *Attention: From Theory to Practice*, Human-Technology Interaction, Kapitel 13, S. 187–195. Oxford University Press, New York, 2007.
- Nadine B. Sarter, David D. Woods, und Charles E. Billings. Automation surprises. In Gavriel Salvendy, Hrsg., *Handbook of Human Factors & Ergonomics*, S. 1926–1943. John Wiley & Sons, 1997.

- Falko Saust, Jörn Marten Wille, Bernd Lichte, und Markus Maurer. Autonomous vehicle guidance on braunschweig's inner ring road within the stadtpilot project. In *2011 IEEE Intelligent Vehicles Symposium (IV'11)*, 2011.
- Frank Schieber, Bernd Schlorholtz, und Robert McCall. Visual requirements of vehicular guidance. In Candida Castro, Hrsg., *Human Factors of Visual and Cognitive Performance in Driving*, S. 31–50. CRC Press, 2009.
- Daniel Schleidt. Die neue Welt der Produktion. *INNOVATIONSMANAGER*, S. 9–11, December 2012.
- Christian D. Schunn und Dieter Wallach. Evaluating goodness-of-fit in comparison of models to data. In W. Tack, Hrsg., *Psychologie der Kognition: Reden and Vorträge anlässlich der Emeritierung von Werner Tack*, S. 115–154. University of Saarland Press, Saarbrücken, Germany, 2005.
- Manfred Schweigert. *Fahrerblickverhalten und Nebenaufgaben*. Dissertation, Technische Universität München, 2003.
- Rod Seeley, Trent Stephens, und Philip Tate. *Anatomy and Physiology*. McGraw-Hill, 6. edition, 2003.
- Rathindra P. Sen. *Operations Research: Algorithms And Applications*. PHI Learning Pvt. Ltd., 2010.
- John W. Senders. *Visual Scanning Processes*. Dissertation, University of Tilburg, Netherlands, 1983. Lawrence Erlbaum Assoc., Hillsdale, NJ, 1984.
- J.W. Senders. The human operator as a monitor and controller of multidegree of freedom systems. *Human Factors in Electronics, IEEE Transactions on*, HFE-5 (1):2–5, September 1964.
- Alain Serval, Andreas Knapp, Christoph Jung, Eckart Donner, Elmar Dilger, Fabio Tango, Johannes Mihm, Juergen Schwarz, Keith Wood, Luciano Ojeda, Markus Neumann, Martin Brockmann, Matthias Meyer, Miklós Kiss, Maxime Flament, Paul Kompfner, Rainer Walz, Sally Cotter, Thomas Winkle, und Wiel Janssen. Code of practice for the design and evaluation of adas. online (www.prevent-ip.org), October 2006. URL http://www.prevent-ip.org/download/deliverables/RESPONSE3/D11.2/Response3_CoP_v3.0.pdf. V3.0.
- Claude Elwood Shannon. A mathematical theory of communication. *Bell Systems Technical Journal*, 27:379–423,623–656, 1948.
- Scott A. Shappell und Douglas A. Wiegmann. Hfacs analysis of military and civilian aviation accidents: A north american comparison. In *Proceedings of 2004 Seminar of International Society of Air Safety Investigators (ISASI)*, 2004. URL http://asasi.org/papers/2004/Shappell%20et%20al_HFACS_ISASI04.pdf.
- Thomas B. Sheridan und William L. Verplank. Human and computer control of undersea teleoperators. Technical report, M.I.T, Man-Machine Laboratory, Cambridge, Massachusetts, 1978.
- Barbara G. Shinn-Cunningham. Object-based auditory and visual attention. *Trends in Cognitive Sciences*, 12(5):182–186, 2008.

- Richard D. Smallwood. Internal models and the human instrument monitor. *IEEE Transactions on Human Factors in Electronics*, HFE-8(3):181–187, 1967.
- SoarTech. Soar: A comparison with rule-based systems. online., 2002. URL <http://ai.eecs.umich.edu/soar/sitemaker/docs/misc/SoarRBSComparison.pdf>. 3600 Green Road suite 600, Ann Arbor, MI 48105. letzter Zugriff: 27.06.2011.
- Neville A. Stanton, Paul M. Salmon, Guy H. Walker, Chris Baber, und Daniel P. Jenkins. *Human Factors Methods: A Practical Guide for Engineering and Design*. Ashgate Publishing, Ltd., 2005.
- Statistisches Bundesamt. Verkehr - Verkehrsunfälle - September 2013. online., 10. Januar 2014. URL <https://www-ec.destatis.de>. Artikelnr: 2080700131094. letzter Zugriff: 21.01.2014.
- Lowell Staveland. Man-machine integration design and analysis system (midas) task loading model (tlm) experimental and software detailed design report. Technical Report NASA CR-177640, National Aeronautics and Space Administration, US Army Aviation Systems Command, May 1994. URL http://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19940030200_1994030200.pdf.
- Kelly S. Steelman-Allen und Jason S. McCarley. Modeling the control of attention in complex visual displays. In *Proceedings of the 19th Conference on Behavior Representation in Modeling and Simulation (BRIMS)*, S. 140–145, Charleston, SC, März 2010.
- Kelly Sheridan Steelman-Allen. *Modeling the Control of Visual Attention in Complex Workspaces*. Dissertation, University of Illinois at Urbana-Champaign, Urbana, Illinois, 2011.
- Kelly Sheridan Steelman-Allen, Jason S. McCarley, Christopher Wickens, Angelia Sebok, und Julie Bzostek. N-SEEV: A computational model of attention and noticing. In *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, volume 53, S. 774–778. SAGE, October 2009.
- Martina Straube. Volkswirtschaftliche kosten durch straßenverkehrsunfälle 2009. *Forschung kompakt*, 04:1–2, 2011.
- Heikki Summala, Tapio Nieminen, und Maaret Punto. Maintaining lane position with peripheral vision during in-vehicle tasks. *Human Factors*, 38(3):442–451, 1996.
- Heikki Summala, Dave Lamble, und Matti Laakso. Driving experience and perception of the lead car’s braking when looking at in-car targets. *Accident Analysis and Prevention*, 30(4):401–407, 1998.
- Niels A. Taatgen. *Learning without Limits: From Problem Solving Towards a Unified Theory of Learning*. Dissertation, Rijksuniversiteit Groningen, 1999.
- Niels A. Taatgen und John Anderson. Constraints in cognitive architectures. In Ron Sun, Hrsg., *The Cambridge Handbook of Computational Psychology*, Kapitel 6, S. 170–186. Cambridge University Press, Cambridge, UK, 2008.
- Niels A. Taatgen und John R. Anderson. The past, present, and future of cognitive architectures. *Topics in Cognitive Science*, 2(4):693–704, October 2010.

- Chris M.J. Tampère. *Human-Kinetic Multiclass Traffic Flow Theory and Modelling*. Dissertation, Technische Universität Delft, December 2004.
- Fabio Tango, Marco Botta, Luca Minin, und Roberto Montanari. Non-intrusive detection of driver distraction using machine learning algorithms. In Helder Coelho, Rudi Studer, und Michael Wooldridge, Hrsg., *Proceeding of the 19th European Conference on Artificial Intelligence (ECAI)*, S. 157–162, Amsterdam, The Netherlands, 2010. IOS Press.
- Benjamin W. Tatler. Characterising the visual buffer: Real-world evidence for overwriting early in each fixation. *Perception*, 30:993–1006, 2001.
- Jan Theeuwes. Exogenous and endogenous control of attention: The effect of visual onsets and offsets. *Perception and Psychophysics*, 49(1):83–90, 1991.
- Jan Theeuwes. Perceptual selectivity for color and form: On the nature of the interference effect. Technical Report TNO-TM 1994 B-11, TNO Defense Research, 3769 ZG Soesterberg, The Netherlands, 1994. URL <http://www.cs.vu.nl/~cogsci/cogpsy/theeuwes/Eriksen.pdf>. letzter Zugriff: 05.01.2013.
- Louis Tijerina, Frank S. Barickman, und Elizabeth N. Mazzae. Driver eye glance behavior during car following. Technical Report DOT HS 809 723, National Highway Traffic Safety Administration, Vehicle Research and Test Center East Liberty, OH 43319, April 2004.
- Anne Treisman. Preattentive processing in vision. *Computer Vision, Graphics, and Image Processing*, 31(2):156–177, August 1985.
- Jennifer S. Trueblood und Jerome R. Busemeyer. A quantum probability account of order effects in inference. *Cognitive Science*, 35(8):1518–1552, November/December 2011.
- Omer Tsimhoni und Yili Liu. Modeling steering using the queueing network - model human processor (qn-mhp). In *Proceedings of the Human Factors and Ergonomics Society 47th Annual Meeting*, S. 1875–1879, Santa Monica, 2003.
- Ali Y. Ungoren und Huei Peng. An adaptive lateral preview driver model. *Vehicle System Dynamics*, 43(4):245–260, April 2005.
- Aad W. van der Vaart. *Asymptotic Statistics*. Cambridge Series in Statistical and Probabilistic Mathematics. Cambridge University Press, 2000.
- Verband deutscher Maschinen- und Anlagenbau – VDMA. Entwicklung des robotik- und automationsumsatzes in deutschland in den jahren 2002 bis 2012. Technical report, VDMA, Mai 2012. zitiert nach de.statista.com, <http://de.statista.com/statistik/daten/studie/225700/umfrage/gesamtumsatz-von-robotik-in-deutschland/>, Abruf am 27.05.2008.
- Lars Weber, Martin Baumann, Andreas Lüdtke, und Rike Steenken. Modellierung von Entscheidungen beim Einfädeln auf die Autobahn. In Antje Lichtenstein, Christian Stöckel, und Caroline Clemens, Hrsg., *Der Mensch im Mittelpunkt technischer Systeme: 8. Berliner Werkstatt, Mensch-Maschine-Systeme*, S. 86–91, Düsseldorf, Oktober 2009. VDI Verlag.

- Eric W. Weisstein. Sinusoid. From *MathWorld* – A Wolfram Web Ressource. online, 2013a. URL <http://mathworld.wolfram.com/Sinusoid.html>. letzter Zugriff: 24.10.2013.
- Eric W. Weisstein. Pointwise convergence. From *MathWorld* – A Wolfram Web Ressource. online, 2013b. URL <http://mathworld.wolfram.com/PointwiseConvergence.html>. letzter Zugriff: 16.12.2013.
- Julia Werneke und Mark Vollrath. How do environmental characteristics at intersections change in their relevance for drivers before entering an intersection: Analysis of drivers' gaze and driving behavior in a driving simulator study. *Cognition, Technology & Work*, online, February 2013.
- Carol J. Wheatley. Visual perceptual aspects of driving. *Ophthalmic and Physiological Optics*, 24(3), 2001. American Occupational Therapy Association, Inc.
- Christopher D. Wickens. Multiple resources and performance prediction. *Theoretical Issues in Ergonomics Science*, 3(2):159–177, 2002.
- Christopher D. Wickens. Multiple resources and mental workload. *Human Factors*, 50(3):449–455, Juni 2008.
- Christopher D. Wickens und Jason S. McCarley. *Applied Attention Theory*. CRC Press, Boca Raton, 2008.
- Christopher D. Wickens, John Helleberg, Juliana Goh, Xidong Xu, und William J. Horrey. Pilot task management: Testing an attentional expected value model of visual scanning. Technical Report ARL-01-14/NASA-01-7, University of Illinois, Aviation Research Lab, Savoy, IL, November 2001.
- Christopher D. Wickens, Juliana Goh, John Helleberg, William J. Horrey, und Donald A. Talleur. Attentional models of multitask pilot performance using advanced display technology. *Human Factors*, 45(3):360–380, 2003a.
- Christopher D. Wickens, Jason S. McCarley, und Lisa C. Thomas. Attention-situation awareness (A-SA). In D. C. Foyle, A. Goodman, und B. L. Hooy, Hrsg., *Proceedings of the 2003 Conference on Human Performance Modeling of Approach and Landing with Augmented Displays*, S. 189–225, Moffett Field, CA: NASA., 2003b. NASA/CP-2003-212267.
- Christopher D. Wickens, Amy L. Alexander, Lisa C. Thomas, William J. Horrey, Ashley Nunes, Thomas J. Hardy, und Xianjun Sam Zheng. Traffic and flight guidance depiction on a synthetic vision system display: The effects of clutter on performance and visual attention allocation. Technical Report AHFD-04-10/NASA(HPM)-04-1, NASA Ames Research Center, Moffett Field, CA, 2004.
- Christopher D. Wickens, Jason S. McCarley, Amy L. Alexander, Lisa C. Thomas, Michael Ambinder, und Sam Zheng. Attention-situation awareness (A-SA) model of pilot error. Technical Report AHFD-04-15/NSA-04-5, University of Illinois, Aviation Human Factors Division, Savoy, IL, 2005. URL http://human-factors.arc.nasa.gov/ih/hcsl/publications/Wickens_AHFD_04_15.pdf. letzter Zugriff: 05.01.2013.

- Christopher D. Wickens, Jason S. McCarley, Amy L. Alexander, Lisa C. Thomas, Michael Ambinder, und Sam Zheng. Attention-situation awareness (A-SA) model of pilot error. In David C. Foyle und Becky L. Hooey, Hrsg., *Human Performance Modeling in Aviation*, S. 213–239. CRC Press/Taylor & Francis Group, New York, 2008.
- Hermann Winner und Gabriele Wolf. Quo vadis, FAS? In Hermann Winner, Stephan Hakuli, und Gabriele Wolf, Hrsg., *Handbuch Fahrerassistenzsysteme*, Kapitel 44, S. 664–673. Vieweg + Teubner, Wiesbaden, 2009.
- Samuel Wintermute. An overview on spatial processing in soar/svs. Technical Report CCA-TR-2009-01, University of Michigan, Center for Cognitive Architecture, An Arbor, Michigan, 23 June 2009.
- Samuel B. Wintermute. *Abstraction, Imagery, and Control in Cognitive Architecture*. Dissertation, University of Michigan, 2010.
- Spektrum Akademischer Verlag, wissenschaft online. Aufmerksamkeit — Lexikon der Neurowissenschaften. online., 2012. URL <http://www.wissenschaft-online.de/abo/lexikon/neuro>. letzter Zugriff: 01.07.2012.
- Jeremy M. Wolfe. Guided search 4.0: Current progress with a model of visual search. In Wayne D. Gray, Hrsg., *Integrated Models of Cognitive Systems*, Kapitel 8, S. 99–119. Oxford University Press, New York: Oxford, 1 edition, April 2007.
- Bertram Wortelen und Andreas Lüdtkke. Adaptive simulation of monitoring behavior: The adaptive information expectancy model. In *Proceedings of the Sixth International Conferences on Advances in Computer-Human Interactions*, S. 413–419, Februar 2013.
- Bertram Wortelen, Malte Zilinski, Martin Baumann, Elke Muhrer, Mark Vollrath, Mark Eilers, Andreas Lüdtkke, und Claus Möbus. Modelling aspects of longitudinal control in an integrated driver model: Detection and prediction of forced decisions and visual attention allocation at varying event frequencies. In Pietro Carlo Cacciabue, Magnus Hjälmdahl, Andreas Lüdtkke, und Costanza Riccioli, Hrsg., *Human Modeling in Assisted Transportation: Models, Tools and Risk Methods*, S. 181–189. Springer Italia, Milano, 2011.
- Bertram Wortelen, Martin Baumann, und Andreas Lüdtkke. Dynamic simulation and prediction of drivers' attention distribution. *Transportation Research Part F: Traffic Psychology and Behaviour*, 21:278–294, 2013a. doi: 10.1016/j.trf.2013.09.019.
- Bertram Wortelen, Andreas Lüdtkke, und Martin Baumann. Integrated simulation of attention distribution and driving behavior. In William G. Kennedy, Robert St. Amant, und David Reitter, Hrsg., *Proceedings of the 22nd Annual Conference on Behavior Representation in Modeling & Simulation*, S. 69–76, Ottawa, Canada, 2013b. BRIMS Society.
- Bertram Wortelen, Andreas Lüdtkke, und Martin Baumann. Simulating attention distribution of a driver model: How to relate expectancy and task value? In Robert West und Terry Stewart, Hrsg., *Proceedings of ICCM 2013 - 12th International Conference on Cognitive Modeling*, S. 269–274, Ottawa, Canada, 11-14 July 2013c.

- Rose T. Zacks und Lynn Hasher. Frequency processing: A twenty-five year perspective. In Peter Sedlmeier und Tilmann Betsch, Hrsg., *ETC. Frequency Processing and Cognition*, Kapitel 2, S. 21–36. Oxford University Press, 2002.

Index

- Ablaufplanungsalgorithmus, 16, 83, 99
- Agentenkonfigurationsdatei, 41
- AIE, 61–89
- Aktivierung, 50
- alternative Bearbeitung, 64
- ambiente Wahrnehmung, *siehe* Wahrnehmung
- associate, 226
- Assoziation, 49
- Assoziative Ebene, 52–54
- Aufgaben
 - priorität, 68–69, 95, 115, 116, 122
 - prozedur, 31
 - struktur, 63–68, 121
- Aufmerksamkeit, 18–21
 - endogene, 14
 - exogene, 14
 - mentale, 18, 21
 - visuelle, 18, 21
- Aufmerksamkeitsgewicht, 69, 87, 97
- Automation, 2–4
- Autonome Ebene, 52, 140

- Blick, 15
 - ablenkungsdauer, 17
 - bewegung, 43, 44, 223
 - dauer, 16, 108, 168
 - frequenz, 16, 23, 108, 156
 - verhalten, 14–18, 35, 38, 39
 - verteilung, *siehe* prozentuale Blickverweilzeit
 - verweilzeit, *siehe* Prozentuale Blickverweilzeit

- CASCaS, 40–57, 85–88
- Chunk, 34

- Daten
 - aufzeichnung, 125
 - selektion, 127
- Datenakquisealgorithmus, 16, 44, 83, 85

- Ereignis, 24, 28, 72–73, 86, 115

- funktion, 75, 75–80, 160–161, 165–167
- rate, 73, 86, 115–173
- Erwartung, 86
- Expected-Value-Modell, 28, 82
- Eye-Mind-Annahme, 15
- Eyetracker, 119

- Fahrerassistenzsystem, 58
- Fahrerassistenzsysteme, 3
- Fahrerinformationssystem, 58
- Fahrermodell, 36, 38, 138–148
- Fahrsimulator, 118
- Fehlerrate, 134
- festе Aufgabensequenz, 65
- Fixation, 14, 44
- freie Sequenz, 66

- Gedächtnisdeskriptor, 49, 223
- Gedächtniselement, 49
- Gedächtniskomponente, 40, 49, 226
- Goal, 224

- Handbewegung, 43, 45

- Immediacy-Annahme, 15
- Informationsaufnahme, 55
- Informationsquelle, 43, 55, 124, 223
- Informationswert, 124
- Infotainmentsystem, 4
- Instruktion, 121
- Interaktionsphase, 45

- Kognitive Architektur, 29–39
- Kognitive Ebene, 51
- Kognitiver Agent, 31
- Kognitives Modell, 31
- Komponenteninitialisierung, 226
- Konfliktmenge, 54, 55
- Konvergenz, 77, 106–110, 165
- Kopfbewegung, 44

- Lateralkontrolle, 121, 132, 139–144

- Lernphase, 77, 165
 Longitudinalkontrolle, 121, 133, 144–146
 LookAt, 55, 223
 Low-Level-Vision, 44, 99
 Lowest Ordinal Algorithmus, 69, 71, 86

 Memorize, 226
 Motor, 225
 Motorkomponente, 41, 45, 223

 Nebenaufgabe, 121
 NRBT, *siehe* Number Read Back Task
 Number Read Back Task, 121, 146

 peripheres Sichtfeld, 141
 Positionierungsphase, 45
 präattentive Wahrnehmung, 13
 präattentives Merkmal, 141
 Priorität, *siehe* Aufgabenpriorität
 Produktionsregel, *siehe* Regel
 Prozedur, 41, 53
 -sprache, 53
 prozentuale Blickverweilzeit, 16, 26, 108, 127, 155

 Randomisierung, 122
 Reaktionsphase, 44, 45
 Reaktionszeit, 134
 Regel, 34, 53, 54, 221
 -LHS, 54, 221
 -RHS, 54, 221
 -aktion, 222
 -auswahl, 54
 -bedingung, 222
 -kopf, 54, 221
 -stärke, 54
 -typ, 54, 221
 reaktiv, 54, 55
 regulär, 54, 55, 95
 Wahrnehmungs-, 54, 55, 94, 95
 Warte-, 54, 56, 95
 Relevanz, 124

 Sakkade, 14, 44
 SEEV
 additiv, 87
 multiplikativ, 87
 SEEV-Modell, 26–29, 39
 Senders' Experiment, 91
 Simulationsumgebung, 41
 Simulatorübelkeit, 126
 Skill, 52, 140

 Streckenprofil, 120

 Topologie, *siehe* Umgebungstopologie
 Transition, 15
 Transitionswahrscheinlichkeit, 17, 99, 157, 172

 Umgebungstopologie, 43, 55, 148, 223

 Versuchsaufbau, 92, 117
 Versuchsdesign, 122
 Versuchspersonen, 94, 117
 Voice, 225

 Wahrnehmung, 11
 ambiente, 12, 13, 20, 141
 fokale, 12, 13, 20
 foveale, 12
 periphere, 12
 präattentive, 13
 Wahrnehmungskomponente, 40
 Wert, 86
 Wissensverarbeitung, 40, 51

 Ziel, 46, 86
 -auswahl, 48, 68–71, 86
 -warteschlange, 48, 87
 persistent, 46, 47
 transient, 46, 224
 Zielagenda, 86, 87, 100, 226
 Zielkomponente, 41
 Zielmodul, 46
 Zielmodus, 46, 47

Versicherung

Hiermit versichere ich, dass ich diese Arbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel verwendet habe. Der Inhalt der Arbeit wurde nicht bereits für eine Diplom- oder ähnliche Prüfungsarbeit verwendet. Weiterhin sind alle für die Erstellung der Arbeit benutzten Hilfsmittel vollständig in der Arbeit angegeben. Außerdem versichere ich, dass ich die allgemeinen Prinzipien wissenschaftlicher Arbeit und Veröffentlichung, wie sie in den Leitlinien guter wissenschaftlicher Praxis der Carl von Ossietzky Universität Oldenburg und den DFG-Richtlinien festgelegt sind, befolgt habe.

Oldenburg, den 29. October 2014

Bertram Wortelen