

Neurophysiologische Analyse des kognitiven Fahrerzustandes

Dissertation

der Mathematisch-Naturwissenschaftlichen Fakultät
der Eberhard Karls Universität Tübingen
zur Erlangung des Grades eines
Doktors der Naturwissenschaften
(Dr. rer. nat.)

vorgelegt von
M. Sc. Michael Simon
aus Schmalkalden

Tübingen
2013

Tag der mündlichen Qualifikation: 22.07.2013
Dekan: Prof. Dr. Wolfgang Rosenstiel
1. Berichterstatter: Prof. Dr. Wolfgang Rosenstiel
2. Berichterstatter: Dr. Michael Schrauf

Zusammenfassung

Eine beträchtliche Anzahl von Verkehrsunfällen ist auf eine Übermüdung des Fahrzeugführers zurückzuführen, insbesondere während Fahrten bei Nacht, aber auch während monotoner Tagfahrten. Die Ergebnisse dieser Arbeit und auch die Unfallzahlen belegen, dass Autofahrer die eigene Müdigkeit häufig unterschätzen. Deshalb arbeiten Automobilhersteller verstärkt an Systemen, die den Fahrer warnen und zur Pause auffordern noch bevor gefährlicher Sekundenschlaf entsteht. Diese Arbeit verfolgt das Ziel ein objektives Referenzsystem, basierend auf physiologischen Daten, insbesondere dem EEG, für die Erfassung von Müdigkeit im realen Straßenverkehr zu entwickeln, welches bei der Absicherung und Weiterentwicklung von Fahrerassistenzsystemen Verwendung findet.

Grundlage der Müdigkeitserkennung mittels EEG sind Alpha-Spindeln, kurzzeitige sinusförmige Bursts im alpha-Band. Mit Hilfe eines personenadaptiven Verfahrens können charakteristische Parameter der Alpha-Spindeln extrahiert werden. Anhand von Tagfahrexperimenten im realen Straßenverkehr zeigen sich signifikante Zusammenhänge zwischen sicherheitskritischer Müdigkeit und mehreren Parameter der Alpha-Spindeln, insbesondere mit der Spindelrate, welche die Auftretenshäufigkeit der Alpha-Spindeln in einem Zeitfenster angibt. Praktisch relevant ist darüber hinaus die signifikante Korrelation der Spindelrate und einer Verschlechterung des Fahrverhaltens, quantifiziert durch Veränderungen im Lenkverhalten.

Fahrtabschnitte zu Beginn und Ende der Fahrt von Probanden, die die Fahrt wegen starker Müdigkeit frühzeitig abgebrochen haben, lassen sich mittels quadratischer Diskriminanzanalyse sehr gut trennen ($AUC = 0,96$). Als Merkmale kommen Spindel- und Lidschlagparametern zum Einsatz. Unter Hinzunahme von Probanden, die die Fahrt nicht abgebrochen haben lässt sich ein 5 min Fahrtabschnitt der Abbrecher kurz vor Fahrtabbruch von allen übrigen Fahrtabschnitten mit einem AUC von $0,845$ trennen. Hier findet eine regularisierte logistische Regression Verwendung.

Alpha-Spindeln stehen ferner im Zusammenhang mit selektiven Aufmerksamkeitsprozessen. Reaktionszeiten auf akustische Reize, die während einer Alpha-Spindel auftreten sind merklich kürzer ebenso ist die Erkennungsrate für solche Reize höher. Aufmerksamkeitsschwankungen sind im Straßenverkehr eine entscheidende Ursache für Verkehrsunfälle. Die Möglichkeit solche Schwankungen im EEG abzubilden stellt ein wichtiges Werkzeug dar, um Korrelate von Aufmerksamkeits-

veränderungen im Fahrverhalten zu erforschen.

Da EEG-Aufzeichnungen im Fahrzeug häufig starke Artefakte zeigen ist eine Bereinigung bzw. ein Ausschluss verrauschter Segmente unerlässlich. Hierzu wird für EOG Artefakte ein Regressionsverfahren verwendet, welches die Bereinigung des EEG in Echtzeit ermöglicht. Muskuläre Artefakte und technische Störungen werden mit Hilfe eines zeitvariablen AR-Modells detektiert und von der weiteren Verarbeitung ausgeschlossen.

Inhaltsverzeichnis

Abbildungsverzeichnis	v
Tabellenverzeichnis	vii
1 Einleitung	1
1.1 Müdigkeit und Vigilanz	2
1.2 Müdigkeitsindikatoren im Fahrkontext	5
1.2.1 subjektive Maße	6
1.2.2 physiologische Maße	7
1.2.3 Leistungsmaße	15
1.3 Zielsetzung und Aufgabenstellung	17
2 EEG Alpha-Spindeln	19
2.1 Detektionsverfahren	24
2.1.1 offline Detektion	24
2.1.2 online Detektion	26
2.2 Performanceanalyse	27
2.3 FaSor	31
2.3.1 Experiment I	32
2.3.2 Experiment II	37
2.3.3 Abbrecher	37
2.3.4 Relation zwischen EEG und Fahrverhalten	54
2.4 Alpha-Spindeln und visuelle Aufmerksamkeit	61
2.4.1 Experimentbeschreibung	65
2.4.2 statistische Methoden	67
2.4.3 Ergebnisse	80
2.4.4 Diskussion	95

3	Klassifikation	99
3.1	Klassifikation der Abbrecher	103
3.1.1	Diskriminanzanalyse	105
3.1.2	Ergebnisse	108
3.2	Prädiktion des Abbruchereignisses	113
3.2.1	Logistische Regression	116
3.2.2	L_1 -Regularisierung	117
3.2.3	Ergebnisse	120
4	Artefakte im EEG	127
4.1	Artefaktdetektion vs. Artefaktbereinigung	129
4.1.1	Artefaktdetektion	129
4.1.2	Artefaktbereinigung	131
4.2	Grundlagen	133
4.2.1	Biologische Artefakte	133
4.2.2	Technische Artefakte	135
4.3	EOG-Bereinigung	135
4.4	EMG-Artefaktdetektion	143
4.4.1	Stationäre autoregressive Modelle	145
4.4.2	Zeitvariable autoregressive Modelle	148
4.4.3	Ergebnisse	154
5	Zusammenfassung und Ausblick	167
A	Veröffentlichungen	173
	Literaturverzeichnis	175

Abbildungsverzeichnis

1.1	Müdigkeitsmodell	5
1.2	EEG und Schlafphasen	9
1.3	Statistik zur Befundlage	14
2.1	Beispiel Spindelaktivität	21
2.2	Alpha- und Schlafspindeln	23
2.3	Amplitudendichtespektrum	25
2.4	RecView	28
2.5	ROC simulierte Daten	31
2.6	Fotos Versuchsträger	33
2.7	Versuchsstrecke	34
2.8	Ergebnisse Experiment I	36
2.9	Studienübersicht	38
2.10	Ergebnisse Experiment II	42
2.11	relativer Anstieg	43
2.12	Vergleich Abbrecher und Nicht-Abbrecher	45
2.13	ROC Kurve: Zeitauflösung	47
2.14	Topographien der Spindelraten	49
2.15	Zeitliche Entwicklung Spindelrate, Alpha-Power	52
2.16	Lenkereignis	55
2.17	Korrelation Lenkereignisse - Spindelrate	58
2.18	Topoplot Korrelation Lenkereignisse - Spindelrate	59
2.19	Laborversuch: experimenteller Aufbau	66
2.20	logistische Verteilung	77
2.21	Laborversuch: Stichprobe	80
2.22	Laborversuch: Spindelrate	81
2.23	Laborversuch: individuelle ALMs	82
2.24	Laborversuch: individuelle ALMs - Korrelationen	84

2.25	Laborversuch: Boxplot individueller Profile	87
2.26	Laborversuch: QQ-Plot der Residuen	88
2.27	Laborversuch: GLMM	90
2.28	Fahrversuch: LMM	93
2.29	Fahrversuch: GLMM	94
3.1	ROC - Abbrecher	109
3.2	AUC vs. Fensterlänge	110
3.3	Korrelation: Reaktionszeit - Klassifikatorscore	111
3.4	Beispiele - Klassifikatorscore	112
3.5	Schema: Vorhersage Abbruch	114
3.6	beschränkte Parameterregionen	119
3.7	a-priori Verteilung Lasso	120
3.8	AUC: logistische Regression mit Lasso	121
3.9	Regularisierung der Regressionskoeffizienten	122
3.10	Histogramme der Regressionskoeffizienten	125
3.11	a-posteriori Wahrscheinlichkeit der beiden Probandengruppen	126
4.1	Artefaktbeispiele	130
4.2	EOG: Elektrodensetup	138
4.3	VEOG: unipolar vs. bipolar	139
4.4	Topoplot: mittlere Regressionskoeffizienten	140
4.5	Topoplot: Reduktion Blinzlamplitude	141
4.6	Einfluss der EOG-Bereinigung auf Spektrum und Amplitude	142
4.7	AR-Modell	145
4.8	RMSE Vergleich	157
4.9	rMSE Topoplot	158
4.10	AUC Vergleich	160
4.11	AUC Topoplot	161
4.12	ROC-Kurven	162
4.13	Fehlerwahrscheinlichkeit	163
4.14	Beispiel zeitvariables AR-Modell	165

Tabellenverzeichnis

1.1 Studienübersicht	13
2.1 Genauigkeit der Parameterschätzung	30
2.2 Übersicht über die Kanalgruppen	40
2.3 MANOVA: Fahrtabschnitt x Kanalgruppe	41
2.4 MANOVA: Fahrtabschnitt x Abbruch	44
2.5 AUC-Werte: Zeitauflösung	48
2.6 MANOVA: Fahrtabschnitt x Abbruch, weitere Bänder	53
2.7 Laborversuch: Modell 1	85
2.8 Laborversuch: LQT	85
2.9 Laborversuch: Modell 4	86
2.10 Laborversuch: GLMM: LQT	89
2.11 Laborversuch: GLMM: Modell 3	89
2.12 Fahrversuch: Stichprobe	91
2.13 Fahrversuch: LMM	92
2.14 Fahrversuch: GLMM: LQT	92
2.15 Fahrversuch: GLMM: Modell 3	94
3.1 Mittelwerte der Regressionskoeffizienten	123
4.1 Kalman Notation des AR-Modells	153

Kapitel 1

Einleitung

Schätzungen zufolge ist der Mensch durch unangepasstes oder fehlerhaftes Verhalten bei ca. 90% aller Verkehrsunfälle der Hauptauslöser (DESTATIS, 2009). Neben dem bewussten Verstoß gegen Verkehrsregeln (z.B. Geschwindigkeitsübertretung), können eine Reihe von kognitiven Fahrerzuständen identifiziert werden, welche die sichere Teilnahme am Straßenverkehr beeinträchtigen oder unmöglich machen. Insbesondere ist das sichere Führen eines Kraftfahrzeugs durch solche Zustände häufig gefährdet. Zu nennen sind hier vor allem Müdigkeit und Unaufmerksamkeit des Fahrers (NHTSA, 2006), welche mehrere fahrrelevante, psychomotorische Fähigkeiten negativ beeinflussen.

Die Ergebnisse auf dem Gebiet der Unfallforschung zeigen, dass Müdigkeit eines der Hauptprobleme in sicherheitskritischen Arbeitsumgebungen und dem öffentlichen Straßenverkehr darstellt (Dinges, 1995). Die polizeilich erfassten Verkehrsunfälle mit Müdigkeit als Hauptgrund betragen zwar nur ca. 2–4% aller Unfälle (NHTSA, 2006), es wird jedoch angenommen, dass Müdigkeit in einer wesentlich größeren Anzahl von Fällen der eigentliche Auslöser ist, denn die Rekonstruktion des Unfallherganges ermöglicht nur selten die eindeutige Identifikation von Müdigkeit als Ursache. Eine Reihe von Studien schätzt, dass 15–25% der Verkehrsunfälle mit Müdigkeit in Verbindung stehen (Horne und Reyner, 1999; Dawson et al., 2000; Hell und Langwieder, 2001; Connor et al., 2002; NHTSA, 2003).

Neben den frühen Morgenstunden (3–6 Uhr), ist auch für eine Phase am Nachmittag (14–16 Uhr) eine Häufung müdigkeitsbezogener Unfälle feststellbar (Pack et al., 1995; Folkard, 1997). Beide Phasen fallen mit Leistungstiefs zusammen, welche durch den zirkadianen Rhythmus verursacht werden (Birbaumer und Schmidt, 2006), wobei die Ermüdungsgefahr am Nachmittag oft unterschätzt wird.

Die Verletzungsschwere bei müdigkeitsbedingten Unfällen ist mit solchen unter

Alkoholeinfluss vergleichbar (Pack et al., 1995). Studien von Williamson und Feyer (2000) sowie Dawson und Reid (1997) zeigen, dass schon bei moderatem Schlafentzug eine Verschlechterung der psychomotorischen Performance eintritt, welche vergleichbar ist mit einer Blutalkoholkonzentration von 0,5‰ bis 0,7‰. Eine Nacht Schlafentzug führt bereits zu einer Verschlechterung der Fahrperformance ähnlich zu 1‰ Blutalkohol (Dawson und Reid, 1997; Fairclough und Graham, 1999).

Wie die obigen Zahlen verdeutlichen, entsteht durch Müdigkeit ein nicht zu unterschätzendes Unfallrisiko im Straßenverkehr, weshalb sich die vorliegende Arbeit auf die fahrerbezogene Erfassung von Müdigkeit konzentriert. Eine Selbsteinschätzung der Müdigkeit durch den Fahrer ist zwar möglich, wie die Unfallstatistiken jedoch eindrücklich darlegen, nicht immer zuverlässig. Die Gründe hierfür sind vielschichtig und nach wie vor nicht eindeutig geklärt. Auf die mangelnde Fähigkeit zur Selbsteinschätzung wird in dieser Arbeit ebenfalls genauer eingegangen. Es ist deshalb erstrebenswert Systeme zu entwickeln, welche die Vigilanz des Fahrers automatisiert erfassen können, um bei kritischem Anstieg der Müdigkeit den Fahrer warnen zu können und eine Unterbrechung der Fahrt zu bewirken. Um Systeme optimieren zu können, welche durch Beobachtung des Fahrers oder des Fahrverhaltens Rückschlüsse auf dessen Vigilanz ermöglichen, ist eine objektive und genaue Müdigkeitsreferenz notwendig. Aus zahlreichen Versuchen im Labor und im realen Straßenverkehr ist bekannt, dass diverse physiologische Maße, hier ist insbesondere das Elektroenzephalogramm (EEG) zu nennen, vielversprechende Kandidaten für diese Aufgabe sind, weshalb sich in dieser Arbeit auf die Entwicklung von robusten Algorithmen zur objektiven Messung des Fahrerzustandes mittels EEG konzentriert wird. Neben einer objektiven Referenz für die Fahrerbeobachtung, ist ein solches Maß generell für die Analyse von Ermüdung während sicherheitskritischer Tätigkeiten anwendbar, insbesondere wenn keine anderweitigen Leistungsmaße erhoben werden können, die die Vigilanzreduktion signalisieren.

1.1 Müdigkeit und Vigilanz

Obwohl der Mensch ein intuitives Verständnis für Müdigkeit hat, gibt es im wissenschaftlichen Sprachgebrauch keine eindeutige Definition für diesen Begriff. In der Literatur finden sich eine Vielzahl von Termini für Müdigkeit, welche uneinheitliche Verwendung finden. Deshalb werden in diesem Abschnitt, basierend auf

dem Modell von [May und Baldwin \(2009\)](#) die wichtigsten Definitionen zum Thema Müdigkeit im Bezug zum Fahrkontext erläutert.

[May und Baldwin \(2009\)](#) unterscheiden anhand der ursächlichen Faktoren zwischen schlafbezogener (sleep-related) und aufgabenbezogener (task-related) Müdigkeit (fatigue). Aufgabenbezogene Müdigkeit wird nochmals in aktive und passive Müdigkeit unterteilt.

Unter *Schlafbezogener Müdigkeit*, auch Schläfrigkeit genannt, versteht man den homöostatisch bedingten Schlafdruck, der von endogenen Prozessen bestimmt wird und mit der Zeit die seit dem letzten Schlaf vergangen ist steigt. Ungezügelter Schlaf, sei es durch zu kurze Schlafdauer, schlechte Schlafqualität oder Krankheit (z.B. obstruktive Schlafapnoe) kann die Schläfrigkeit ebenfalls erhöhen ([George et al., 1987](#)). Ein weiterer bedingender Faktor ist der zirkadiane Rhythmus, welcher in den Nachtstunden und am Nachmittag ein Leistungstief hervorruft. So konnte Folkard zeigen, dass die relative Unfallhäufigkeit um 3 Uhr und um 15 Uhr Maximalwerte erreicht ([Folkard, 1997](#)). Schläfrigkeit kann nur durch ausreichend Schlaf reduziert werden, nicht aber durch Pausen oder Bewegung.

Aufgabenbezogene Müdigkeit entsteht immer in Verbindung mit der Ausübung einer Tätigkeit. Aufgaben mit hoher mentaler Beanspruchung wie z.B. Fahren im dichten Verkehr, Navigation während der Fahrt oder schlechte Sicht resultieren in *aktiver* aufgabenbezogener Müdigkeit. Ist die Tätigkeit monoton, stark vorhersehbar und wenig beanspruchend ([Wertheim, 1991](#)), entsteht *passive* aufgabenbezogene Müdigkeit. Bezogen auf das Autofahren tritt die passive Form vermehrt bei monotonen Strecken mit wenig Verkehr wie z.B. Autobahnen auf. [Hancock und Verwey \(1997\)](#) weisen außerdem auf die Gefahr hin durch zunehmende Automatisierung des Fahrens mittels Assistenzsystemen die Monotonie und damit die passive Müdigkeit weiter zu erhöhen. Beiden Formen der aufgabenbezogenen Müdigkeit ist gemein, dass sie erst nach einer gewissen Aufgabendauer (time-on-task) auftreten und im Verlauf der Ausübung der Aufgabe zunehmen. Durch Unterbrechen der Tätigkeit und Pausieren kann eine Verminderung der aufgabenbezogenen Müdigkeit erreicht werden ([Philip et al., 2005](#)).

Bei monotonen Tagfahrten (s. auch Abschnitt [2.3](#)), worauf in dieser Arbeit ein Schwerpunkt gelegt wird, tritt demnach primär passive aufgabenbezogene Müdigkeit auf. Am Nachmittag kann durch das Leistungstief des zirkadianen Rhythmus noch Schläfrigkeit hinzu kommen. Nachtfahrten sind durch den zirkadianen Rhythmus, vor allem nach 24 Uhr, hauptsächlich von Schläfrigkeit geprägt, allerdings ist auch hier bei monotonen Fahrten zusätzlich mit passiver aufgaben-

bezogener Müdigkeit zu rechnen. Konfundierungen der verschiedenen Typen von Müdigkeit sind in Realfahrtexperimenten also unvermeidbar. [May und Baldwin \(2009\)](#) weisen allerdings darauf hin, dass alle hier erwähnten Formen der Müdigkeit mit den gleichen Methoden messbar sind, in Bezug auf EEG und EOG also ähnliche physiologische Veränderungen hervorrufen.

Als Folgen von Müdigkeit lassen sich die Begriffe Vigilanzdekrement und „drowsiness“ („Benommenheit“) einordnen (s. Abbildung 1.1). [Mackworth \(1957\)](#) definiert Vigilanz folgendermaßen: „readiness to detect and respond to certain specified small changes occurring at random time intervals in the environment“. Eine Vigilanzaufgabe, wie das Autofahren auf monotonen Strecken, ist eine Form der Umgebungsbeobachtung, in der die Aufmerksamkeit und Reaktionsbereitschaft über einen längeren Zeitraum auf eine oder mehrere Informationsquellen gerichtet werden muss, um seltene, unregelmäßige Ereignisse zu erkennen und angemessen darauf zu reagieren ([Ballard, 1996](#); [Sieloff, 2009](#)). Sinkende Leistungsfähigkeit in einer solchen Aufgabe wird als Vigilanzdekrement bezeichnet. „Drowsiness“ bezeichnet umgangssprachlich den eher subjektiven, physiologischen Zustand reduzierter Aufmerksamkeit und Leistungsfähigkeit ([Johns, 2000](#); [Schmidt, 2010](#)), meist einhergehend mit einer Verschlechterung der Stimmung.

Physiologisch gesehen ist vor allem der Erregungszustand des zentralen Nervensystems für das Vigilanzniveau verantwortlich ([Grandjean, 1979](#)). Nach diesem Modell ist der momentane Zustand eine Summe aus agonistischen (Retikularformation, limbisches System) und antagonistischen (Neuronennetzwerke im Hirnstamm und Zwischenhirn) Prozessen, welche wiederum durch Hormone wie Adrenalin und Melatonin (zirkadianer Rhythmus) sowie Emotionen und Motivation beeinflusst werden. Der Einfluss der Motivation, bzw. die damit verbundene Anstrengung wach zu bleiben, erklärt auch den nicht-monotonen Verlauf der Müdigkeit bei Vigilanzaufgaben ([Lal und Craig, 2005](#)), wo sich Phasen von starker Ermüdung (Sekundenschlaf) mit weniger beeinträchtigten Phasen abwechseln, da diese Anstrengung nur für jeweils kurze Phasen aufrecht erhalten werden kann ([Kecklund und Åkerstedt, 2004](#); [Hole, 2007](#)). Beim Kampf gegen das Einschlafen findet also ein Wechselspiel zwischen agonistischen und antagonistischen Prozessen statt. Es ist außerdem bekannt, dass es individuelle Unterschiede in der Anfälligkeit für Müdigkeit bei Vigilanzaufgaben gibt ([Desmond und Matthews, 2009](#)).

Wie bereits erwähnt, führt jegliche Art von ausreichend hoher Müdigkeit zu einer Verschlechterung der Fahrleistung. [Brown \(1994\)](#) beschreibt eine Internalisierung der Aufmerksamkeit, hervorgerufen durch Müdigkeit, welche in einer Ver-

schlechterung der Fahrperformance resultiert. Nach [Hole \(2007\)](#) ist der Kampf gegen die Müdigkeit ein „mental effort“, welcher nur für kurze Zeitspannen aufrecht erhalten werden kann. Mit zunehmender Müdigkeit steigt die Aversion gegen diese Anstrengung und wird folglich reduziert, was in verminderter kognitiver und motorischer Leistungsfähigkeit resultiert und Einbußen in der Fahrleistung zur Folge hat.

1.2 Müdigkeitsindikatoren im Fahrkontext

In diesem Abschnitt wird auf die Operationalisierung des Begriffs Müdigkeit eingegangen, die die Messung von Müdigkeit während des Autofahrens, z.B. im realen Straßenverkehr, erlaubt. Übliche Methoden zur Erfassung von Müdigkeit sind die Erhebung subjektiver Maße (Selbsteinschätzung), Verhaltensmaße und physiologische Maße. Der nicht-monotone Verlauf sowie die individuelle Anfälligkeit für Müdigkeit bei Vigilanzaufgaben wie Autofahren (s. Abschnitt 1.1) erschweren zudem deren objektive Erfassung. In der vorliegenden Arbeit finden Maße aus allen

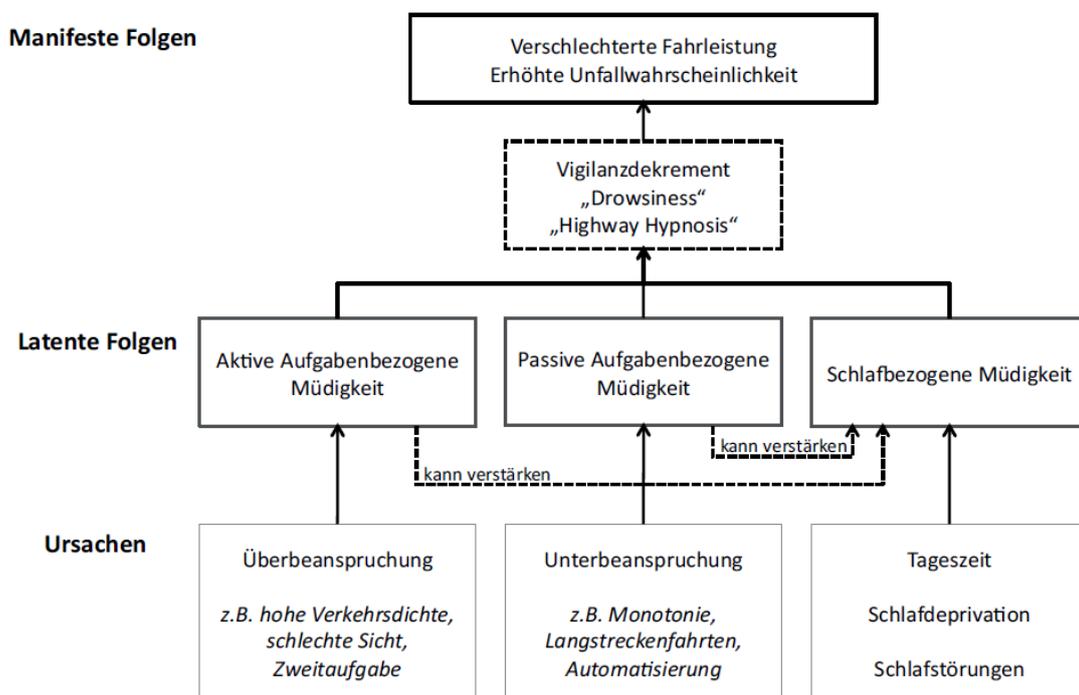


Abbildung 1.1: Müdigkeitsmodell nach [May und Baldwin \(2009\)](#) - aus [Schmidt \(2010\)](#)

drei Kategorien Anwendung, wobei der Schwerpunkt auf physiologischen Maßen liegt. Vor- und Nachteile der verschiedenen Methoden werden im Folgenden erörtert.

1.2.1 subjektive Maße

Eine direkte Möglichkeit der Erfassung von Müdigkeit besteht in der Befragung der Probanden über den eigenen Zustand. Die Fähigkeit der Selbsteinschätzung scheint offensichtlich und gewinnt besonders beim Autofahren einen sicherheitskritischen Aspekt, da vor allem nicht-professionelle Fahrer selbst über notwendige Pausen oder die Beendigung der Fahrt entscheiden müssen. In der Fachliteratur finden sich mehrere subjektive Maße, mit entweder analoger (Visual Analogue Scale (VAS): [Monk, 1989](#)) oder diskreter Bewertungsskala (Karolinska Sleepiness Scale (KSS): [Åkerstedt und Gillberg, 1990](#); Stanford Sleepiness Scale (SSS): [Hoddes et al., 1973](#); Epworth Sleepiness Scale (ESS): [Johns, 1991](#)). In dieser Arbeit wird die Karolinska Sleepiness Scale verwendet, da sie situative Müdigkeit zu einem bestimmten Zeitpunkt erfassen kann ([Åkerstedt und Gillberg, 1990](#)), im Gegensatz zu Skalen wie der Epworth Sleepiness Scale ([Johns, 1991](#)), welche die generelle Einschlafneigung messen. Da jede Abfrage eine Interaktion mit der Versuchsperson darstellt, wird das Experiment beeinflusst und kann deshalb nicht beliebig oft durchgeführt werden ([Schmidt et al., 2011](#)). In der Literatur sind Intervalle von 5 bis 20 Minuten üblich, was die zeitliche Auflösung subjektiver Maße deutlich einschränkt.

Über die Validität subjektiver Maße gibt es kontroverse Aussagen in der Fachliteratur. Mehrere Autoren berichten von einer plausiblen Einschätzung der eigenen Müdigkeit bei Autofahrern ([Reyner und Horne, 1998](#); [Otmani et al., 2005](#); [Baranski, 2007](#)). Im Gegensatz dazu kommen andere Studien zu dem Ergebnis, dass kein ausgeprägter Zusammenhang zwischen der Selbsteinschätzung und Reaktionszeiten oder der Fahrleistung besteht ([Philip et al., 2003](#); [Belz et al., 2004](#); [Moller et al., 2006](#)). In Abschnitt [2.3.1](#) wird dieses Problem noch ausführlicher behandelt.

Es ist weiterhin bekannt, dass die kognitive Leistungsfähigkeit mit zunehmender Müdigkeit abnimmt. Vermutlich rührt dies aus einer Deaktivierung des präfrontalen Kortex ([Thomas et al., 2000](#)), welcher für höhere kognitive Funktionen verantwortlich ist. Es ist daher auch anzunehmen, dass die Fähigkeit der Selbsteinschätzung, als eine höhere mentale Leistung mit steigender Müdigkeit abnimmt.

Letztendlich belegen auch die Unfallstatistiken, dass nicht immer ausreichende introspektive Fähigkeiten vorhanden sind.

Zusätzlich besteht die Gefahr, dass subjektive Maße bewusst manipuliert oder falsch interpretiert werden können, was zu verzerrten Ergebnissen in Vigilanzexperimenten führen kann.

1.2.2 physiologische Maße

Eine weitere Möglichkeit der Operationalisierung von Müdigkeit besteht in der Erfassung physiologischer Vorgänge. Vorteile dieser Maße sind eine hohe Objektivität, keine willentliche Beeinflussung, geringe Interferenz mit der Fahraufgabe und eine hohe zeitliche Auflösung. Es liegt auf der Hand physiologische Daten heranzuziehen, da Ermüdung mit veränderten physiologischen Prozessen im Körper einhergeht. Im Gegensatz zu Leistungsmaßen, welche nur indirekt, durch eine Interaktion des Probanden mit der Umwelt Müdigkeit messen können, stellen physiologische Maße eine direkte Messmethode dar.

In der Literatur ist eine Vielzahl von Maßen bekannt, die mit Müdigkeit in Verbindung gebracht werden. Unter anderem ist dies das Elektrokardiogramm (EKG, [Brookhuis und de Waard, 1993](#); [Schmidt et al., 2009](#)), denn bei Ermüdung, bis in den Schlaf hinein, sinkt die Herzrate kontinuierlich ab, was eine reduzierte Aktivierung des vegetativen Nervensystems darstellt. Auch zeigt sich eine veränderte Herzratenvariabilität ([Tran et al., 2009](#)). Kardiologische Maße sind nur ein relativ unspezifischer Indikator für Müdigkeit, da andere Prozesse wie Stress und Anstrengung ebenfalls Einfluss auf das EKG haben ([Smiley, 2007](#)).

Darüber hinaus kann die Konzentration des Hormons Melatonin im Körper Rückschlüsse auf die Müdigkeit erlauben ([Cajochen et al., 1999](#)). Melatonin ist maßgeblich für die Steuerung des zirkadianen Rhythmus verantwortlich. Es wird bei Dunkelheit vermehrt produziert und geht mit einer Zunahme der Schläfrigkeit einher. Die Konzentration gibt also Aufschluss über die zirkadiane Phase, in der sich der Organismus gerade befindet. Effekte aufgabenbezogener Müdigkeit lassen sich mit Melatonin also nicht erfassen.

Weitere Maße, die zur Erfassung von Müdigkeit Verwendung finden sind u.a. Elektromyographie (EMG, [Dureman und Bodén, 1972](#)), der Hautleitwiderstand ([Wright und McGown, 2001](#)) oder die Pupillographie ([Wilhelm et al., 2001](#)).

1.2.2.1 Elektroenzephalographie

Die Elektroenzephalographie (EEG) ermöglicht die Messung neurophysiologischer Vorgänge im Kortex. Insbesondere lässt sich auf Grund der hohen zeitlichen Auflösung die spektrale Zusammensetzung der neuronalen Aktivität im EEG gut analysieren. Es ist bekannt, dass die synchrone Oszillation von Zellverbänden eine maßgebliche Rolle in der Informationsverarbeitung des Gehirns spielen (Engel et al., 2001). Der Einschlafvorgang und auch die darauf folgenden unterschiedlichen Schlafstadien sind mit grundlegenden Veränderungen der neurophysiologischen Prozesse verbunden (Rechtschaffen und Kales, 1968). Deshalb bietet das EEG eine direkte Messung von müdigkeitsbedingten neuronalen Prozessen und wird in einer Vielzahl von Studien bereits erfolgreich eingesetzt.

EEG Untersuchungen lassen sich einteilen in die Analyse des Spontan-EEGs, d.h. die Messung fortlaufender Neuronenaktivität an verschiedenen Positionen auf dem Schädel und in die Analyse ereigniskorrelierter Potentiale (EKP), welche als Reaktion des Gehirns auf externe Stimuli hervorgerufen werden. Eine detaillierte Beschreibung der Grundlagen des EEGs findet sich z.B. in Niedermeyer und Silva (2005).

Das EKP ist im Spontan-EEG nicht oder kaum sichtbar, da es durch stimulusirrelevante fortlaufende Aktivität überlagert wird. Durch Mittelung der EEG-Aktivität vieler Stimuluspräsentationen kann das EKP-Muster allerdings aufgedeckt werden, da das nicht-phasensynchrone Hintergrund-EEG durch die Mittelung eliminiert wird. Das EKP wird in lokale Maxima und Minima abhängig von ihrer Latenz zum Stimulus unterteilt. Einige Studien zeigen, dass die P300-Komponente, ein Maximum zwischen 300 ms und 600 ms nach dem Stimulus, Veränderungen durch Vigilanz erfährt (Koelega et al., 1992; Curcio et al., 2001; Schmidt et al., 2009). Die zeitliche Auflösung des EKPs ist allerdings eingeschränkt, da (i) die Mittelung über viele Trials einen längeren Zeitraum umfasst und (ii) nur unerwartete Stimuli eine ausgeprägte P300-Komponente erzeugen und sich dadurch das Interstimulusintervall verlängert (Schmidt, 2010).

Bei der Untersuchung des Spontan-EEGs wird die Aktivität üblicherweise in fünf Frequenzbänder unterteilt, die jeweils mit verschiedenen kognitiven Prozessen in Verbindung gebracht werden. Hierzu wird meist die Leistung in einem oder mehreren Frequenzbändern unter verschiedenen Experimentbedingungen untersucht. Im Folgenden wird eine kurze Auflistung der einzelnen Bänder und ihrer kognitiven Bedeutung gegeben. Die exakten Bandgrenzen variieren in der Literatur.

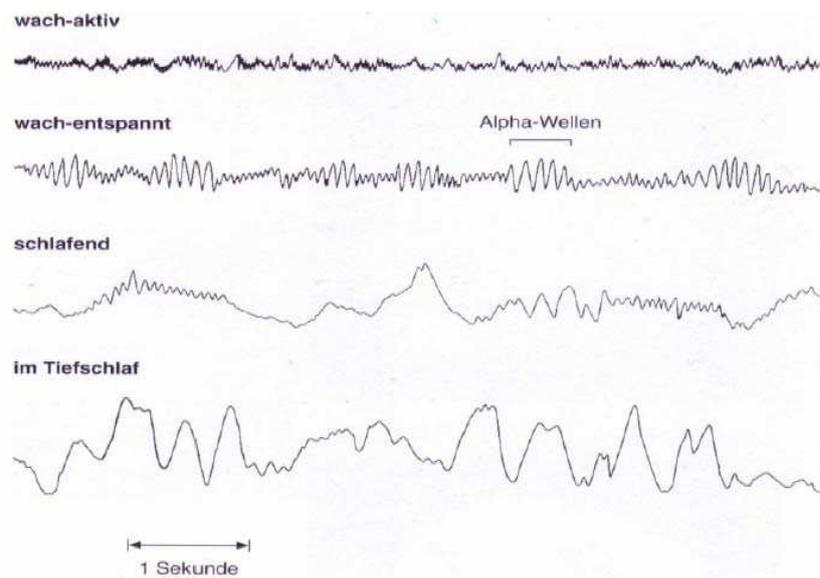


Abbildung 1.2: Veränderungen des EEGs vom Wachzustand bis in den Tiefschlaf.

Auch existieren interindividuelle Unterschiede in den Grenzfrequenzen. Die folgende Einteilung orientiert sich an den Angaben in [Niedermeyer und Silva \(2005\)](#).

Das *Delta-Band* umfasst hochamplitudige Wellen mit einer Frequenz von bis zu 3,5 Hz. Diese treten hauptsächlich in Tiefschlafphasen auf (engl. “slow wave sleep“, [Rechtschaffen und Kales, 1968](#)), weniger dominant auch in früheren Schlafphasen (s. [Abbildung 1.2](#)). Außer in pathologischen Zuständen werden Delta-Wellen im Wachzustand nicht beobachtet.

Das *Theta-Band* reicht von ca. 4–7 Hz und tritt hauptsächlich beim Übergang in den Schlaf (s. [Abbildung 1.2](#)) und in Phasen tiefer Entspannung ([Cantero et al., 2003](#)) auf. Darüber hinaus wird Theta-Aktivität auch mit Gedächtnisprozessen in Verbindung gebracht ([Klimesch, 1996](#)).

Das *Alpha-Band* (7–13 Hz) ist der dominante Rhythmus des EEGs. Er tritt im Wachzustand bei geschlossenen Augen besonders stark im parietalen und okzipitalen Kortex auf und wird beim Öffnen der Augen blockiert. Dieser Effekt ist bei ca. 85% der Erwachsenen beobachtbar. Das Alpha-Band ist einer der am häufigsten untersuchten EEG-Rhythmen und wird mit den unterschiedlichsten psychologischen Phänomenen assoziiert. Dazu zählen Gedächtnisprozesse, Alterung, Intelligenz, Bewusstsein und vor allem Aufmerksamkeit ([Ray und Cole, 1985](#); [Klimesch, 1999](#); [Cooper et al., 2003](#)). So zeigen mehrere Studien verlangsamte Reaktionszeiten bei erhöhter Alpha-Aktivität als Folge verminderter Aufmerksamkeit

auf visuelle Reize (Hanslmayr et al., 2007; Romei et al., 2008; van Dijk et al., 2008). Im Zusammenhang mit modalitätsspezifischer Aufmerksamkeit (z.B. akustisch oder visuell) hat die Inhibitionshypothese besondere Relevanz (Foxe et al., 1998; Pfurtscheller und da Silva, 1999; Klimesch et al., 2007). Diese Theorie besagt, dass synchron schwingende Zellverbände im Alpha-Frequenzbereich in ihrer Verarbeitung aktiv blockiert werden. Auf diese Weise werden aufgabenirrelevante kortikale Areale gehemmt, wie z.B. der visuelle Kortex bei internalisierter Aufmerksamkeit oder auditorischen Aufgaben. Werden dagegen visuelle Informationen verarbeitet, verschwindet der Alpha-Rhythmus (Desynchronisation). Unter diesem Aspekt lässt sich auch die Zunahme der Alpha-Aktivität bei Ermüdung interpretieren. Bei zunehmender Müdigkeit werden weniger visuelle Informationen verarbeitet, was zu einer Inhibition des visuellen Kortex führt. Dies ist u.a. eine Folge der Internalisierung der Aufmerksamkeit (Brown, 1994). Die Zunahme der Alpha-Aktivität mit steigender Müdigkeit ist in vielen Studien nachgewiesen worden (Åkerstedt und Gillberg, 1990).

Das *Beta-Band* (14–30 Hz) wird häufig mit erhöhter Aufmerksamkeit, Konzentration und mentaler Aktivität in Zusammenhang gebracht und ist damit ein Gegenspieler zum Alpha-Rhythmus.

Das *Gamma-Band* (35–100 Hz) wird erst in neuerer Zeit intensiver untersucht und ist noch immer Gegenstand kontroverser Diskussionen. Durch Oszillationen im Gamma-Band wird eine top-down Regulierung der Wahrnehmung und Informationsverarbeitung vermutet, außerdem ist Gamma-Aktivität entscheidend für die Entstehung von Zellverbänden (Engel et al., 2001), welche für die Ausbildung höherer kognitiver Funktionen notwendig sind. Weiterhin steht die Steuerung selektiver Aufmerksamkeit (Tallon-Baudry et al., 1997) und Lernen (Miltner et al., 1999) mit Gamma-Aktivität in Verbindung.

1.2.2.2 Elektrookulographie

Das Auge ist elektrophysiologisch betrachtet ein Dipol, welcher durch das sog. korneoretinale Bestandpotenzial (Birbaumer und Schmidt, 2006) entsteht. Die Retina ist dabei negativ und die Kornea positiv geladen. Um das Auge herum platzierte Elektroden können Änderungen des Dipolfeldes messen und dadurch Augenbewegungen erfassen. Diese Methode wird allgemein als Elektrookulographie (EOG) bezeichnet. Typische Bewegungsmuster sind zum einen Sakkaden (horizontal und vertikal), welche durch einen Blickrichtungswechsel entstehen und zum anderen

durch Lidschluss bedingte Änderungen des Dipolfeldes, was sich ausschließlich in vertikaler Richtung äußert. Der Lidschluss (eyeblick) ruft eine stereotype Änderung des Dipolfeldes hervor, die sich gut mit Elektroden oberhalb bzw. unterhalb des Auges messen lässt. Veränderungen des Lidschlussverhaltens werden häufig für die Messung von Müdigkeit verwendet. Es wird angenommen, dass unbewusste Lidschlagverhalten einerseits durch die Hirnstamm-Aktivierung und andererseits durch zentralnervöse Hemmung gesteuert wird (Meinold, 2005). Es ist bekannt, dass Kerne im Thalamus direkten Einfluss auf die Motorneuronen der Augenmuskulatur haben und dass die Aktivität solcher Kerne sowohl bei Vigilanzfluktuationen als auch im Schlaf (REM, nicht-REM) Veränderungen erfährt (Kandel et al., 2000). In diesem Zusammenhang werden eine Reihe von Parametern aus dem Lidschlussverhalten extrahiert, welche helfen sollen Müdigkeit zu quantifizieren. Die bekanntesten und am häufigsten verwendeten Maße sind PER-CLOSE (Prozent der Zeit, die das Auge zu mehr als 80% geschlossen ist, U.S. Department of Transportation, 1999), Blinzelfrequenz Stern et al. (1994), Blinzeldauer (Caffier et al., 2003; Schleicher et al., 2008), Blinzelamplitude (Morris und Miller, 1996) und Anteil langsamer Blinzler (Caffier et al., 2003).

Eine attraktive Möglichkeit bei der Messung des Lidschlusses stellt die Beobachtung mit Kamera dar, da dies kontaktfrei möglich ist und somit hohe praktische Relevanz hat. Bei kamerabasierten Verfahren ist auch eine Messung der Lidschlussgeschwindigkeit möglich, was durch fehlende Kalibration beim EOG nicht ohne Weiteres möglich ist. Erfahrungen im Rahmen dieser Arbeit mit verschiedenen kommerziellen Systemen haben allerdings gezeigt, dass eine reliable Messung mittels Kamera noch nicht zufriedenstellend möglich ist. Reflexionen durch Brillen, Abwenden des Kopfes (z.B. Blick in den Rückspiegel) und schlechte Lichtverhältnisse (Gegenlicht) führen zu häufigen Messaussetzern.

1.2.2.3 Literaturübersicht

Nach einem Abriss über potentielle physiologische Maße für Müdigkeit, wird nun eine Übersicht über Studien gegeben, welche Maße aus dem EEG zur Identifikation von Müdigkeit im Fahrkontext verwenden, da das EEG auch Hauptuntersuchungsgegenstand der vorliegenden Arbeit ist. Tabelle 1.1 gibt eine Zusammenfassung der relevanten Literatur zu diesem Thema.

Müdigkeit wird in den analysierten Studien durch Schlafentzug, Fahren bei Nacht oder lange monotone Fahrten, bzw. eine Kombination daraus, moduliert.

Erfasst wird Müdigkeit über Befragungen, Fahrperformance, Expertenrating oder Kontrastierung von Experimentbedingungen (z.B. Tag/Nacht). Die Resultate der Studien werden eingeteilt in einen signifikanten Anstieg des untersuchten EEG-Maßes mit zunehmender Müdigkeit (positiver Zusammenhang), eine Abnahme mit Müdigkeit (negativer Zusammenhang) oder keinem signifikanten Zusammenhang.

Insgesamt zeigt sich eine heterogene Befundlage mit teils widersprüchlichen Ergebnissen. Dies liegt zum Teil daran, dass die Studien nur bedingt vergleichbar sind, da es bedeutende Unterschiede in den Experimentbedingungen und Messverfahren gibt. Eine zusammenfassende Statistik der Befunde findet sich in Abbildung 1.3. Am häufigsten findet die Leistung im Alpha-Band Verwendung. Die meisten Studien finden einen Anstieg der Alpha-Power mit zunehmender Müdigkeit. Eine Abnahme wird nicht beobachtet. Das Theta-Band zeigt in einigen Studien ebenfalls einen positiven Zusammenhang mit Müdigkeit, allerdings ist der Anteil nicht-signifikanter Resultate höher und die Stärke des Effekts generell geringer als für das Alpha-Band. Ergebnisse für das Delta- und Beta-Band sind als unsicher einzuschätzen, da sie nicht oft verwendet werden und, besonders für das Beta-Band, keine klare Tendenz erkennbar ist. Das Verhältnis $\text{Theta}+\text{Alpha}/\text{Beta}$ ($((\theta+\alpha)/\beta)$) steigt in den meisten Studien mit zunehmender Müdigkeit, jedoch wird es deutlich seltener als das Alpha- oder Theta-Band untersucht. Besonders interessant für diese Arbeit sind die Ergebnisse für Theta- und Alpha-Bursts, mit dem bloßen Augen sichtbare, kurze, dominante Aktivität in diesen Frequenzbändern, welche von den Autoren in ähnlicher Weise definiert wird wie die später noch zu beschreibenden Alpha-Spindeln. Die Analyse der Bursts ist in den untersuchten Studien nicht automatisiert. Stattdessen werden die Bursts von Hand identifiziert und gezählt, d.h. die Auftretenshäufigkeit in einem Zeitintervall ermittelt. Auf Eigenschaften wie Dauer und Amplitude der Bursts wird nicht eingegangen. Alle Studien, welche Theta- oder Alpha-Bursts untersuchen, berichten einen signifikanten Anstieg der Häufigkeit von Bursts mit fortschreitender Ermüdung. Zusammenfassend scheinen die Leistung im Alpha-Band und die Beobachtung von kurzzeitigen Bursts im Theta- und Alpha-Band die vielversprechendsten Indikatoren für Müdigkeit zu sein.

Die Gründe für die teils unterschiedlichen Ergebnisse sind unklar, aber es ist anzunehmen, dass die stark variierenden Experimentbedingungen wie z.B. Tageszeit oder die Verwendung von schlafdeprivierten Probanden einen erheblichen Einfluss auf die Resultate ausüben. Außerdem sind Unterschiede in der Messmethodik feststellbar, hier insbesondere die Art der Referenzierung des EEGs.

Autor	Setting	N	Schlaf- ent- zug	Tages- zeit	Dauer	Refer- enz	δ	θ	α	β	$\frac{\theta+\alpha}{\beta}$	θ - burst	α - burst
O'Hanlon, 1977	R	41	nein	n	4,5h	O1-P3	pos.	pos.	pos.	-	-	-	-
Torsvall, 1987	R	11	nein	n	4,5h	??	pos.	pos.	pos.	-	-	-	-
Brookhuis, 1993	R	20	nein	??	3h	??	-	-	-	-	pos.	-	-
Kecklund, 1993	R	18	nein	n	8,5h	Cz-Oz	n.s.	n.s.	n.s.	n.s.	-	pos.	pos.
Bittner, 2000	R	??	ja	??	??	??	-	-	pos.	-	-	-	-
Baulk, 2001	S	10	ja	nm	2h	C3-A1	-	n.s.	n.s.	-	-	-	-
Roge, 2001	S	17	nein	??	2h	A1	-	-	-	-	-	pos.	pos.
Tietze, 2001	S	12	nein	n	~4h	Mv	-	-	-	-	-	-	pos.
Lal, 2002	S	35	ja	nm	2h	Mv	pos.	pos.	pos.	pos.	-	-	-
Tejero, 2002	R	6	nein	vm	45min	O2-P4	-	-	-	-	pos.	-	-
Campagne, 2004	S	46	nein	a	3h	Mr	-	pos.	pos.	n.s.	pos.	-	-
Cerezuela, 2004	R	14	nein	??	45min	C3-A2	-	-	n.s.	-	n.s.	-	-
Horne, 2004	S	38	ja	nm	2h	C3-A1	-	-	pos.	-	-	-	-
Eoh, 2005	S	8	ja	vm	50min	??	-	n.s.	pos.	neg.	pos.	pos.	pos.
Lin, 2005	S	5	nein	nm	45min	A2	-	pos.	pos.	pos.	-	-	-
Otmami, 2005	S	16	ja	nm	90min	A1	-	pos.	pos.	-	-	-	-
Papadelis, 2007	R	10	ja	a	1h	Mv	pos.	n.s.	pos.	neg.	-	-	pos.
Schmidt, 2009	R	19	nein	nm	3,75h	Nase	-	-	-	-	-	-	pos.

Tabelle 1.1: Studienübersicht zum Zusammenhang von physiologischen Maßen mit Müdigkeit im Fahrkontext. Für jedes Maß ist die Art des Zusammenhangs mit Müdigkeit angegeben (positiv, negativ, kein Zusammenhang), Abkürzungen: ?? - keine Angaben, Setting: R - Realfahrt, S - Simulator; N - Anzahl der Versuchspersonen; Tageszeit: vm - vormittags, nm - nachmittags, a - abends, n - nachts; Referenz: Mv - Mastoid verbunden, Mr - Mastoid rechts; Ergebnisse: n.s. - nicht signifikant, Gedankenstrich - nicht untersucht, Eintrag über mehrere Spalten - Maße wurden zusammengefasst

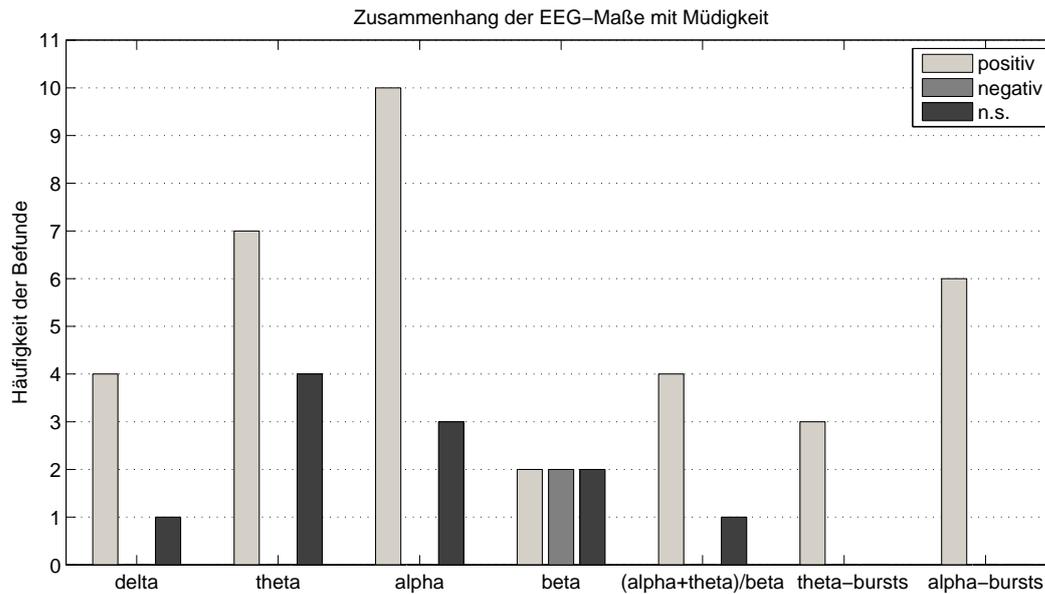


Abbildung 1.3: Häufigkeit der Befunde zum Zusammenhang von EEG-Merkmalen mit Müdigkeit im Fahrkontext

Die Verwendung einer bipolaren Ableitung wie z.B. Cz-Oz oder monopolare Referenzen dürften einen erheblichen Einfluss auf die Ergebnisse haben. Da viele Studien nur wenige, zum Teil sogar nur eine EEG-Elektrode verwenden, lässt sich nicht eindeutig schlussfolgern welche Kortextareale besonders sensitiv auf Veränderungen der Müdigkeit reagieren. Ergebnisse aus Vigilanzstudien außerhalb des Fahrkontextes, mit einer ausreichenden Anzahl Elektroden, deuten allerdings auf zentral-parietale Regionen hin. Beim Autofahren bedarf es allerdings noch einer Validierung dieser Ergebnisse.

Es sei noch darauf hingewiesen, dass Studien, die den Übergang von vollständig wachen Probanden bis zum definitiven Schlaf untersuchen, meist von einer Verlagerung der dominanten Alpha-Aktivität von parietal nach frontal berichten und dabei eine Abnahme der Frequenz um 1–2 Hz beobachten (Hori et al., 1994). Gleichzeitig wird eine Zunahme von Theta-Bandleistung beobachtet, bis Alpha gänzlich verschwindet und im weiteren Verlauf die Delta-Aktivität zunimmt (Cantero et al., 1999; Ogilvie, 2001). Studien, die die Ermüdung des Probanden während der Ausübung einer Tätigkeit untersuchen, berichten in der Regel keine Abnahme des Alpha-Rhythmus mit steigender Müdigkeit, sondern eine Zunahme. Besonders deutlich wird dies in einer Studie von Åkerstedt und Gillberg (1990).

Die Autoren berichten von fast kontinuierlicher Alpha-Aktivität bei einer KSS-Stufe von neun, was verbal „sehr schläfrig, Kampf gegen den Schlaf“ bedeutet, ein Vigilanzniveau, das minimal nötig ist, um noch eine Aufgabe ausführen zu können. Die Diskrepanz in den Ergebnissen lässt sich vermutlich durch das unterschiedliche experimentelle Setup erklären. In reinen Einschlafstudien haben die Probanden meist die Augen geschlossen. Im Wachzustand führt dies zu einer hohen Alpha-Aktivität, welche bei geöffneten Augen, wenn überhaupt, nur bei äußerst starker Ermüdung erreicht werden kann. Experimente mit geschlossenen oder geöffneten Augen können also zu sehr unterschiedlichen Ergebnissen in Bezug auf Alpha führen. In einer fMRT-Studie von [Ben-Simon et al. \(2008\)](#) können sogar unterschiedliche Aktivierungssysteme für den spontanen Alpha-Rhythmus (Thalamus, präfrontaler Kortex) und den durch Augen schließen induzierten Rhythmus (Hippocampus, temporaler Kortex) identifiziert werden. Darüber hinaus sind die Probanden in reinen Einschlafstudien mit keiner Aufgabe beschäftigt und nicht dazu angehalten willentlich gegen den Schlaf zu kämpfen. Da dieser Kampf vermutlich Stress induziert ([Brown, 1994](#); [Lal und Craig, 2001](#)), ist anzunehmen, dass andere psychische Vorgänge ablaufen, welche in abweichenden EEG-Rhythmen resultieren. Die Übertragung von Ergebnissen aus Einschlafstudien im Labor auf Ermüdungsvorgänge während des Fahrens gestaltet sich äußerst schwierig und Vergleiche zwischen Resultaten aus Labor und Fahrzeug sind daher nur bedingt möglich. Es ist durchaus vorstellbar, dass eine Abnahme der Alpha-Aktivität, wie sie in Einschlafstudien berichtet wird, erst in einem Zustand eintritt, in dem Autofahren nicht mehr möglich ist. Bei der 9-stufigen Einteilung von [Hori et al. \(1994\)](#) kommt es z.B. zu einer Abnahme der Alpha-Aktivität bereits innerhalb der ersten drei Stufen, (Stufe neun entspricht Schlafstadium zwei, also definitiver Schlafbeginn) wobei hier sehr wohl Einschlafereignisse auftreten. Dieser Zustand würde beim Autofahren bereits die maximal erreichbare Müdigkeit darstellen, da dann ein Abdriften aus der Spur wahrscheinlich ist (Sekundenschlaf).

1.2.3 Leistungsmaße

Abschließend soll eine Übersicht über verschiedene Leistungsmaße, insbesondere im Fahrkontext, gegeben werden mit welchen Vigilanz operationalisiert werden kann. Die Leistungsfähigkeit in einer bestimmten Aufgabe hat eine hohe Augen-scheinvalidität für die Erfassung von Müdigkeit, da ein Performanceeinbruch direkt als Vigilanzdekrement definiert ist ([Hartley et al., 2000](#)). In Frage kommen

hierbei Performancemaße des Fahrverhaltens selbst oder einer Zweitaufgabe, die während der Fahrt ausgeübt werden kann.

Da grobe Fahrfehler selten sind und bereits einen sicherheitskritischen Zustand darstellen, können diese nicht als Maß für Müdigkeit verwendet werden. Stattdessen bedarf es Maße des Fahrverhaltens, die bereits wesentlich früher auf subtilere Einbrüche in der Vigilanz reagieren und kontinuierlich gemessen werden können. Geläufig ist z.B. die Beobachtung des Lenkverhaltens ([Thiffault und Bergeron, 2003](#)).

Mercedes-Benz „Attention Assist“

Mercedes-Benz hat 2009 das Fahrerassistenzsystem „Attention Assist“ im E-Klasse Modell der Baureihe 212 eingeführt, welches darauf abzielt die Übermüdung von Autofahrern speziell bei monotonen Fahrten auf der Autobahn frühzeitig zu erkennen, noch bevor gefährlicher Sekundenschlaf entsteht ([Daimler AG, 2008](#)). Dabei erfasst das System das individuelle Lenkverhalten in Form von Lenkbewegung und -geschwindigkeit. Charakteristisch für übermüdete Fahrer sind hierbei besonders Lenkaussetzer, kurze Phasen ohne Lenkaktivität, gefolgt von einer typischen Lenkkorrektur. Das System beobachtet die Veränderungen des Lenkverhaltens während einer Fahrt von häufigen kleinen Korrekturen im wachen Zustand hin zu typischen Lenkaussetzern, gefolgt von einer stärkeren Korrektur, bei Ermüdung. Diese Lenkereignisse werden zusätzlich mit Faktoren wie Tageszeit und Fahrdauer gewichtet. Um individuelle Fahr- und Lenkprofile zu berücksichtigen, wird zu Beginn der Fahrt ein Fahrerprofil erstellt, welches bei der Festlegung der individuellen Warnschwelle berücksichtigt wird. Das System berücksichtigt zudem weitere Faktoren, die das Lenkverhalten beeinflussen können wie z.B. Bedienhandlungen des Fahrers, Überholmanöver und äußere Einflüsse, wie Seitenwind und Bodenwellen. Eine detaillierte Beschreibung des Verfahrens findet sich in Kapitel [2.3.4](#). Wird die individuelle Warnschwelle überschritten, ertönt ein Warnton und im Kombiinstrument erscheint das Symbol einer Kaffeetasse mit dem Hinweis „Attention Assist: Pause“. Mittlerweile ist das System auch für andere Mercedes-Benz Modelle wie z.B. S-Klasse, C-Klasse und B-Klasse erhältlich.

Die Standardabweichung der lateralen Position in der Spur ([Ingre et al., 2006](#)), Zeit bis zum Überqueren der Spurbegrenzung (time to lane crossing, [Ting et al., 2008](#)) oder der Abstand zum voraus fahrenden Fahrzeug ([Ting et al., 2008](#)) sind

Maße, die ebenfalls häufig zur Erkennung von Müdigkeit mittels Fahrparametern verwendet werden. Volvos “Driver Alert Control“ ist ein Seriensystem für PKWs, welches auf der Standardabweichung der lateralen Spurposition basiert, die mit Hilfe einer Videokamera erfasst wird. In einer Übersicht von [Liu et al. \(2009\)](#) über Fahrzeugdaten, die mit Müdigkeit in Verbindung gebracht werden fällt auf, dass die einzige Studie, die auf realen Straßen ausgeführt wird keine klaren Veränderungen im Fahrverhalten feststellen kann. Befunde aus dem Fahr Simulator bedürfen also immer einer Validierung auf der Straße. Im realen Straßenverkehr ist z.B. problematisch, dass Ablenkungen des Fahrers, z.B. durch Bedienen des Navigationssystems oder Radios, zu ähnlichen Veränderungen in den Parametern führen können wie Müdigkeit, die Spezifität also herabgesetzt ist. Unterschiedliche Straßentypen und -verhältnisse fügen den Maßen beträchtliche Variabilität hinzu, wodurch kleinere müdigkeitsbedingte Effekte u.U. nicht mehr detektierbar sind. Außerdem ist bekannt, dass es erhebliche Unterschiede im Fahrverhalten zwischen verschiedenen Personen gibt.

Alternativ besteht die Möglichkeit die Performance in einer Zweitaufgabe zu beobachten. Hier besteht die Annahme, dass durch die Zunahme der Müdigkeit insgesamt weniger kognitive Ressourcen zur Verfügung stehen. Da das Führen des Fahrzeugs höhere Priorität hat, kommt es bereits früh zu Leistungseinbrüchen in der Zweitaufgabe ([Hole, 2007](#)). Neben standardisierten Tests (z.B. Psychomotor Vigilance Task (PVT), [Dinges und Powell, 1985](#)), sind vor allem Zweitaufgaben interessant, die während der Fahrt ausgeübt werden können. Hier hat sich insbesondere die Reaktionszeit auf seltene auditorische Reize als sensitiv erwiesen ([Laurell und Lisper, 1978](#); [Schmidt et al., 2009](#)). Langsame Reaktionszeiten treten häufiger auf und verlangsamen sich zunehmend mit steigender Müdigkeit ([Graw et al., 2004](#); [Schmidt et al., 2009](#)), wohingegen schnelle Reaktionszeiten nahezu unverändert bleiben. Die in Kapitel 2 beschriebenen Experimente verwenden einen auditorischen Oddball als Zweitaufgabe und messen hier die Reaktionszeit auf häufige und seltene Töne.

1.3 Zielsetzung und Aufgabenstellung

Ziel dieser Arbeit ist es ein reliables Maß für Müdigkeit aus dem EEG zu extrahieren. Dieses Maß soll insbesondere zur Anwendung außerhalb des Labors im Fahrzeug unter erschwerten Messbedingungen geeignet sein. Dazu soll das Maß ob-

ektiv, d.h. vom Probanden nicht beeinflussbar und von seiner Selbsteinschätzung unabhängig sein, da die zuverlässige Selbsteinschätzung nicht immer gewährleistet ist. Weiterhin ist eine zeitliche Auflösung des Maßes ähnlich der Fluktuation von Müdigkeit anzustreben, welche beim Autofahren vermutlich im Bereich von Minuten liegt. Wichtig bei EEG-Messungen im Fahrzeug ist die Robustheit des Maßes gegen technische und probandeninduzierte Störungen in der Messung. Da ein enger Zusammenhang zwischen Müdigkeit und Aufmerksamkeit besteht, soll zusätzlich untersucht werden inwieweit die entwickelten EEG-Maße mit Aufmerksamkeitsprozessen in Verbindung stehen.

Müdigkeitsrelevante Merkmale sollen in einem zweiten Schritt hinsichtlich ihrer Eignung zur automatisierten Klassifikation von Müdigkeit untersucht werden. Insbesondere sollen Klassifikationsverfahren entwickelt werden, welche eine Anwendung der Methoden in Echtzeit ermöglicht.

Da zu erwarten ist, dass EEG-Aufzeichnungen im Fahrzeug stark von Artefakten belastet sind, soll auch ein besonderes Augenmerk auf die Behandlung von Artefakten gelegt werden. Soweit möglich ist die Bereinigung des EEGs von Artefakten anzustreben, andernfalls soll sich auf eine Detektion von Störungen beschränkt werden. Auch hier ist das Ziel Algorithmen zu entwickeln, welche in Echtzeit während der Aufzeichnung im Fahrzeug anwendbar sind.

Kapitel 2

EEG Alpha-Spindeln

Die Frage nach der Entstehung des kortikalen Alpha-Rhythmus ist nach wie vor Inhalt kontroverser Diskussionen. Eine verbreitete Theorie geht davon aus, dass der Thalamus über thalamokortikale Schleifen einen wesentlichen Einfluß auf EEG-Rhythmen, insbesondere im Alpha-Band hat (da Silva, 1991; Sterman, 1996; Foxe et al., 1998; Pfurtscheller, 2003; Shaw, 2003). Eine PET/EEG-Untersuchung von Schreckenberger et al. (2004) untermauert den engen Zusammenhang zwischen thalamischer Aktivität und kortikaler Alpha-Power. Bei Hyperpolarisation der Neuronen im Thalamus werden ankommende Reize der sensorischen Bahnen nicht mehr weitergeleitet, da sich das Membranpotenzial von der Schwelle, bei der eine Weiterleitung der Erregung möglich ist, entfernt (Birbaumer und Schmidt, 2006). Dieser Zustand ist allerdings nicht stabil. Stattdessen schwingt der Thalamus durch ein Wechselspiel mit dem Nucleus reticularis zwischen Hyper- und Depolarisation und leitet dieses Aktivitätsmuster an die verbundenen Kortextareale weiter (Sterman, 1996). Dieser Prozess ist mitverantwortlich für die typischen Oszillationen, welche mit dem EEG messbar sind. Da den Thalamus alle sensorischen Bahnen passieren, wirkt er durch seine hemmende Eigenschaft für sensorische Information wie ein Tor zu höheren kortikalen Strukturen. Diese Hemmung kann entweder aktiv, z.B. durch selektive Aufmerksamkeitsprozesse, welche irrelevante Reize ausblenden, oder passiv erfolgen z.B. durch Vigilanzabnahme (Sterman, 1996). Beim Schlaf wird die Hemmung durch Teile des Hypothalamus und des basalen Vorderhirns ausgelöst. Allgemeine und selektive Aufmerksamkeit werden durch das so genannte aufsteigende retikuläre Aktivierungssystem (ARAS) gesteuert, welches die Formatio reticularis des Mittel- und Hinterhins, das basale Vorderhirn und den Thalamus beinhaltet (Birbaumer und Schmidt, 2006). Ebenso können kortikothalamische Neurone wiederum den Thalamus und Nucleus reticularis be-

einflussen und die Hemmung tiefer liegende Hirnstrukturen wieder aufheben. Dies findet vermutlich beim willentlichen Kampf gegen Einschlafen statt. Bei Vigilanzaufgaben ist häufig ein nicht-monotoner Verlauf der Ermüdung mit wiederholten Einbrüchen in der Vigilanz und anschließender kurzfristiger Erholung zu beobachten. Ein gleichzeitiger, gegensätzlicher Einfluss auf die thalamokortikal-retikuläre Schleife durch schlafinduzierende tiefere Hirnregionen und bewusste, vom Kortex gesteuerte Handlungen kann diesen Verlauf erklären.

Im Einklang mit dem Modell der Hemmung sensorischer Reize durch den Thalamus bei synchroner Aktivität steht die Theorie, dass dominante Alpha-Aktivität eine Inhibition des entsprechenden Kortexareals darstellt (Pfurtscheller, 2003; Klimesch et al., 2007). Informationsverarbeitung in diesem Bereich ist während hoher Alpha-Aktivität gehemmt oder reduziert. Kommt es hingegen zur Aktivierung des Areals, ist eine Abnahme der Alpha-Aktivität zu beobachten. Dieses Phänomen wird allgemein als Event Related Desynchronisation (ERD) bezeichnet und ist z.B. über dem Motorkortex sehr ausgeprägt (Pfurtscheller und da Silva, 1999). Die Inhibition kann auch durch selektive Aufmerksamkeit und damit verbundene Hemmung aufgabenirrelevanter kortikaler Areale entstehen. Neben aktiver Hemmung kann auch reduzierte Vigilanz eine erhöhte Alpha-Aktivität hervorrufen (Santamaria und Chiappa, 1987). Wie im vorigen Kapitel geschildert, wurde dies auch im Fahrkontext wiederholt beobachtet. Es wird vermutet, dass diese Zunahme der Alpha-Aktivität und die damit verbundene Reduzierung der Informationsverarbeitung bei Ermüdung ebenfalls einer signifikanten Kontrolle des Thalamus unterliegt (Serman, 1996). Diese Annahme wird gestützt durch PET- und fMRT-Studien, die eine Deaktivierung des Thalamus bei Schlafdeprivation und Vigilanzabnahme feststellen (Drummond et al., 1999; Thomas et al., 2000; Olbrich et al., 2009). Eine Studie von Sadaghiani et al. (2010) identifiziert außerdem positive Korrelationen zwischen globaler Alpha-Aktivität und einem tonischen Aufmerksamkeitssystem, welches kortikale Areale, den Thalamus und die Basalganglien beinhaltet.

EEG Alpha-Spindeln

Wie in der Einleitung schon erwähnt, tritt die Alpha-Aktivität durch differenzierte zeitliche Strukturen in Erscheinung. Diese „burst-artigen“ Strukturen, im Weiteren **Alpha-Spindeln** genannt, werden in diesem Kapitel genau charakterisiert und deren Eignung als Müdigkeitsmaß untersucht.

Bei aufgabenbezogener Müdigkeit steigt die Leistung im Alpha-Band nicht

kontinuierlich, sondern durch Zunahme kurzer (500 ms bis mehrere Sekunden), schmalbandiger Bursts im Alpha-Band (Kecklund und Åkerstedt, 1993; Tietze und Hargutt, 2001; Eoh et al., 2005; Papadelis et al., 2007). Eine Beispielsequenz solcher Spindelaktivität ist in Abbildung 2.1 zu sehen. Diese spektralen Mikrostrukturen können durch einen schmalen Frequenzpeak im Alpha-Band (7–13 Hz) und einer niederfrequenten Einhüllenden charakterisiert werden. Die genaue Peakfrequenz variiert sowohl zwischen Personen als auch zwischen Ableitorten über dem Kortex. Eine Alpha-Spindel kann also durch *Peakfrequenz*, *spektrale Amplitude* und *Dauer* beschrieben werden. Zusätzlich kann die Auftretenshäufigkeit von Alpha-Spindeln in einem gewissen Zeitintervall bestimmt werden, im Folgenden als *Spindelrate* bezeichnet.

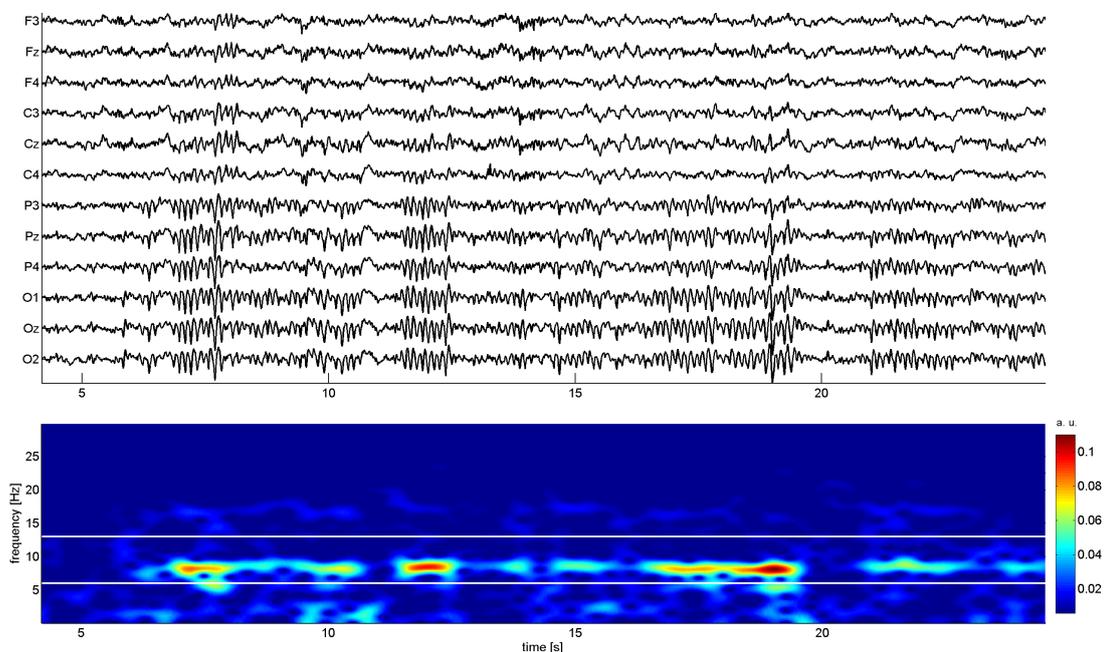


Abbildung 2.1: Beispiel von Alpha-Spindelaktivität, welche hauptsächlich an parieto-okzipitalen Elektroden sichtbar ist, mit abnehmender Intensität auch an anterioren Elektroden. Deutlich zu sehen ist der Burst-Charakter und die niederfrequente Einhüllende der Spindeln. Die untere Grafik zeigt das Spektrogramm des Kanals Oz mit den Alpha-Bandgrenzen (7-13 Hz) weiß markiert. Jede Spindel hat einen zeitlich stabilen schmalbandigen Frequenzpeak von maximal 3,5 Hz Bandbreite, der zwischen Spindeln innerhalb der Bandgrenzen wechseln kann.

Auch wenn Alpha-Spindeln und Schlafspindeln ähnliche funktionelle Bedeutungen zugewiesen werden (Inhibition des beteiligten Kortexareals, s. Kapitel 1.2.2.1 bzw. Steriade (1997) und Klimesch et al. (2007)), sind sie nicht als identische

Phänomene anzusehen. Dies ist aus mehreren Gründen ersichtlich: (i) Schlafspindeln treten in einem teils mit dem Alpha-Band überlappenden, aber höheren Frequenzband von ca. 11,5–16 Hz auf (Ogilvie, 2001). (ii) Schlafspindeln treten beim Übergang vom Wachzustand zu Schlaf erst auf, nachdem die zu Beginn stark ausgeprägte Alpha-Aktivität verschwunden ist und von langsamerer Theta- und Delta-Aktivität ersetzt wird (Rechtschaffen und Kales, 1968). Das simultane Auftreten beider Phänomene wird in der Literatur nicht berichtet. (iii) Schlafspindeln werden weiterhin als Indikator für den Schlafbeginn (Schlafstadium 2, kurz: S2) angesehen (Hori et al., 1994). Dieser Zustand ist nicht mit dem beim Autofahren auftretenden Sekundenschlaf vergleichbar, denn das Schlafstadium 2 ist begleitet von nahezu vollständiger und andauernder Bewusstlosigkeit. Aus diesem Grund können auch Alpha-Spindeln, die bei EEG-Messungen im Fahrzeug beobachtet werden, nicht mit Schlafspindeln identisch sein.

Um die Unterscheidung von Alpha- und Schlafspindeln auch experimentell zu untermauern, wurde im Selbstversuch der Einschlafvorgang mit EEG aufgezeichnet und Alpha-Spindeln im individuellen Alpha-Band (7,5–12,5 Hz) und Schlafspindeln im Sigma-Band (13–15,5 Hz) detektiert. In Abbildung 2.2 sind die Auftretenshäufigkeiten (Spindelraten) der zwei Spindelarten beim Einschlafen dargestellt. Deutlich zu sehen ist der Alpha-Anstieg beim Schließen der Augen und das Verschwinden der Alpha-Aktivität im Schlaf. Umgekehrt dazu steigt die Schlafspindelaktivität im letzten Drittel der Messung deutlich an. Erkennbar ist, wie sich die beiden Prozesse erst im Schlaf ablösen. In müden Phasen davor dominieren Alpha-Spindeln, welche während des Einschlafens verschwinden und erst danach treten Schlafspindeln auf. Der erneute Anstieg der Alpha-Spindelaktivität zu Beginn des Schlafs, bei ca. 90 min, ist vermutlich auf Schlafspindeln zurückzuführen, deren Frequenz an der Grenze zwischen Alpha- und Sigma-Band liegt. Die Bandgrenzen sind Mittelwerte über eine größere Stichprobe und können von Person zu Person variieren (Klimesch, 1999), wodurch eine falsche Zuordnung unterschiedlicher Aktivitäten in benachbarte Bänder für einzelne Probanden entstehen kann. Ebenso lässt sich die erhöhte Schlafspindelaktivität zu Beginn der Messung auf spindelähnliche Beta-Aktivität zurückführen. Durch Konzentration beim Fernsehsehen sind hier ausgeprägte Beta-Wellen vorhanden, welche als Schlafspindeln detektiert werden, da sich das Beta- und Sigma-Band überlappen.

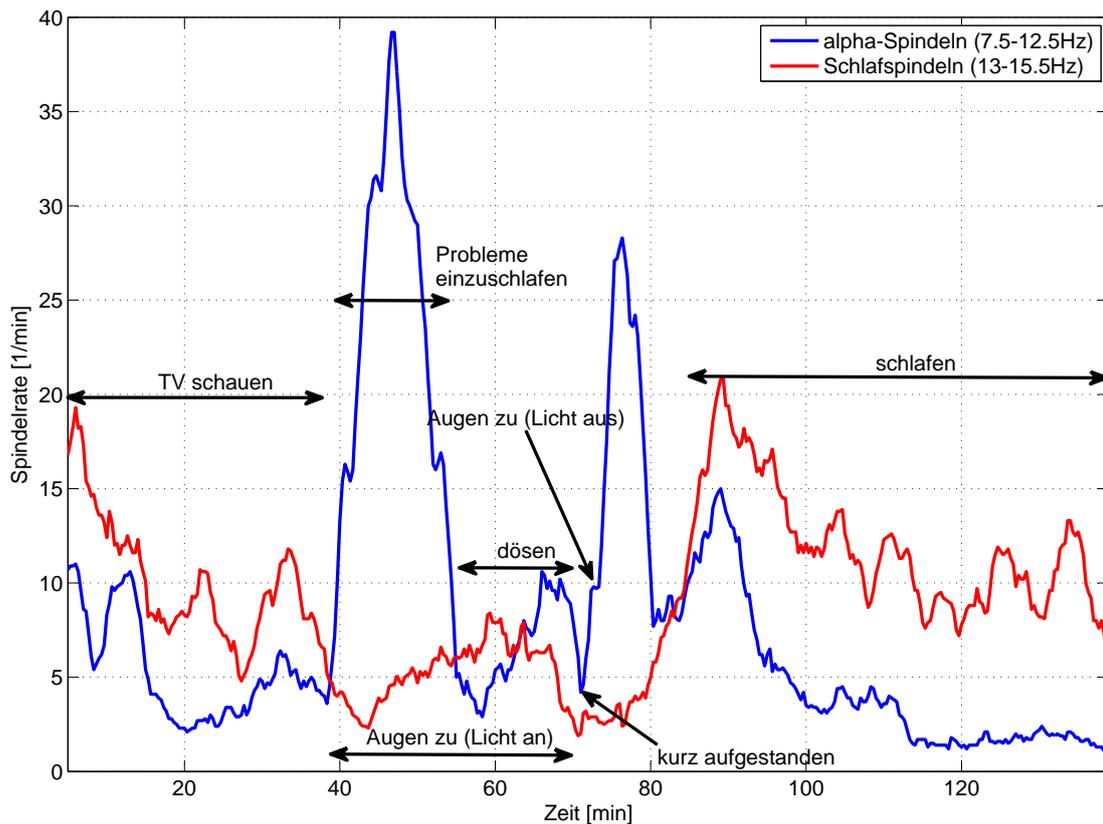


Abbildung 2.2: Vergleich von Alpha-Spindeln und Schlafspindeln beim willentlichen Einschlafen. Aufgetragen ist die Spindelhäufigkeit für das Alpha- und Sigma-Band in einem gleitenden 5 min Fenster. Die erhöhte Aktivität im Sigma-Band zu Beginn der Messung ist burst-artige Beta-Aktivität, welche jedoch deutlich kürzere Bursts aufweist (hier nicht gezeigt).

2.1 Detektionsverfahren

Die folgenden Unterkapitel beschreiben die Algorithmen zur automatisierten Detektion der Alpha-Spindeln und der Extraktion der relevanten Parameter. Die Algorithmen sind vor allem dahingehend optimiert, um unter schlechten Signal-Rausch-Verhältnissen zu operieren und auch in Echtzeit anwendbar zu sein.

Für die Detektion einer Alpha-Spindel gelten folgende Kriterien: (i) es muss ein bestimmtes Signal-Rausch-Verhältnis überschritten werden. (ii) Eine Spindel kann an einer einzelnen Elektrode auftreten. (iii) Die Peakfrequenz einer Spindel ist über deren Dauer hinreichend stabil. (iv) Eine Spindel kann von 0,5 s bis zu mehreren Sekunden andauern.

2.1.1 offline Detektion

Die spektrale Dekomposition des EEGs wird über eine Kurzzeit-Fourier-Transformation (short-time Fourier transform, STFT, [Oppenheim und Schafer, 1989](#)) durchgeführt, um die nicht-stationären Eigenschaften der EEG-Zeitreihen erfassen zu können. Die Fast Fourier Transform (FFT) ermöglicht dabei eine hocheffiziente Implementierung, geeignet für eine Echtzeitanwendung.

Jeder EEG-Kanal wird in Segmente von 1 s Länge und einer Überlappung von 750 ms zerlegt. Jedes Segment wird mittelwertbereinigt und mit einem Hamming-Fenster multipliziert. Anschließend wird für jedes Segment die FFT berechnet und das Maximum im Amplitudendichtespektrum zwischen 3 und 40 Hz ermittelt. Liegt dieses Maximum im definierten Alpha-Band (7–13 Hz), wird es als Spindelaktivität angesehen und die Halbwertsbreite (engl. full width at half maximum, FWHM) des Peaks berechnet. Ist die Halbwertsbreite schmaler als das Zweifache der Rauschbandbreite des Hamming-Fensters, wird dieses Segment weiter analysiert. Da die Bandbreite des Hamming-Fensters die minimale spektrale Auflösung bestimmt, kann ein Frequenzpeak kleiner dieser Breite als monochromatische Oszillation angesehen werden, was Voraussetzung für eine Spindel ist. Es ist bekannt, dass das Rauschspektrum im EEG eine $1/f$ -Charakteristik besitzt ([Pereda et al., 1998](#); [Wagenmakers et al., 2004](#)). Um dieses Rauschen zu approximieren, wird eine exponentielle Kurve an das mittlere Amplitudenspektrum der gesamten Aufzeichnung nach der Methode der kleinsten Quadrate angepasst (Abbildung 2.3). Das mittlere Amplitudenspektrum wird aus dem Mittelwert aller Einzelsegmente bestimmt. Bereiche über der Exponentialkurve werden als Signal interpretiert und

Bereiche darunter als Rauschen. Die Exponentialkurve wird an die unterschiedlichen Rauschlevel zwischen verschiedenen Segmenten angepasst. Dazu wird die Exponentialkurve mit einem Korrekturfaktor multipliziert, welcher das Verhältnis zwischen der Leistung im aktuellen Segment und der mittleren Leistung der gesamten Zeitreihe ist. Die Leistung wird durch Integration über das Spektrum des aktuellen Segments bzw. des mittleren Amplitudenspektrums berechnet.

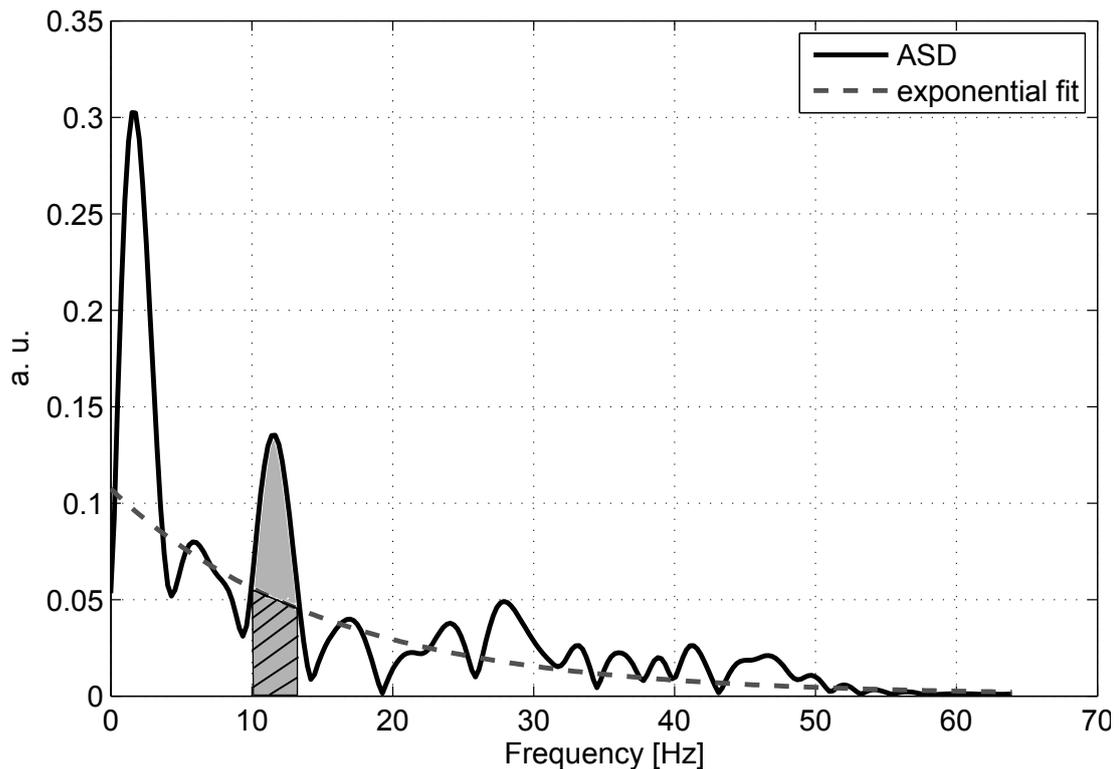


Abbildung 2.3: Amplitudendichtespektrum (ASD) eines 1 s EEG-Segmentes mit ausgeprägter Alpha-Spindelaktivität bei ca. 11,5 Hz. Die angepasste exponentielle Kurve ist als gestrichelte Linie dargestellt. Der Oszillationsindex ist definiert als das Verhältnis der gesamten Fläche unter dem Spindelpeak (grau markiert) und der Fläche unter der Exponentialkurve (gestreift).

Um das Signal-Rausch-Verhältnis (*signal-to-noise ratio*, SNR) von Spindelaktivität und Hintergrundrauschen zu approximieren, wird die Fläche unter dem ermittelten Frequenzpeak im Alpha-Band, begrenzt durch die Halbwertsbreite, und der Fläche im gleichen Frequenzintervall unter der Exponentialkurve ins Verhältnis gesetzt. Dieses Verhältnis wird im Folgenden *Oszillationsindex* genannt. Bei einem Wert größer oder gleich zwei liegt ein ausreichend hohes SNR vor. Aufeinander folgende Zeitsegmente, die dieses Kriterium erfüllen und eine Peakfrequenz

haben, die nicht mehr als 10% vom vorherigen Segment abweicht, werden zu einer Alpha-Spindel zusammengefasst. Die Frequenz der gesamten Spindel ist der Mittelwert der Peakfrequenzen der einzelnen Segmente. Die spektrale Amplitude einer Spindel wird ebenfalls aus dem Mittelwert der Amplituden an den Peakfrequenzen der Segmente berechnet. Die Dauer einer Spindel ist definiert als die Zeitspanne vom Beginn des ersten zugehörigen Zeitsegments bis zum Ende des letzten Segments.

Um Prozesse wie Müdigkeit, die auf Zeitskalen im Minuten- und Stundenbereich fluktuieren abzubilden, werden die Eigenschaften mehrerer Spindeln in einem gleitenden Mittelwertfenster gemittelt. Das erlaubt außerdem die Bestimmung der Auftretenshäufigkeit der Spindeln (*Spindelrate*) im gleichen Fenster.

2.1.2 online Detektion

Im Rahmen dieser Arbeit wird das Detektionsverfahren für Alpha-Spindeln auch dahingehend adaptiert, dass eine Anwendung in Echtzeit möglich ist. Die objektive Erfassung von Müdigkeit in Echtzeit, also bereits während des Versuchs, ist aus mehreren Gründen erstrebenswert. Eine subjektive Validierung des Maßes durch den Versuchsleiter in Bezug auf Müdigkeit bzw. die Beobachtung der Reaktivität des Maßes auf ungeplante Veränderungen der experimentellen Bedingungen wird dadurch ermöglicht. Beides ist hilfreich für die qualitative Beurteilung des Verfahrens, da gerade bei Experimenten im Realverkehr nicht alle externen Einflüsse vorhersehbar und dokumentierbar sind. Weiterhin kann die Beobachtung der Spindelmaße in Echtzeit zur Gewinnung neuer Hypothesen beitragen. Ein adaptives experimentelles Design, welches den aktuellen Zustand des Probanden berücksichtigt, wird damit ebenfalls möglich. Die vielversprechendste Anwendung ist eine automatisierte Beurteilung der Müdigkeit des Probanden in Echtzeit auf Basis der Alpha-Spindeln und ein entsprechendes Feedback an den Probanden mit eventueller Warnung bei Übermüdung.

Die STFT zur Zeit-Frequenz-Analyse des EEGs ist bereits ein echtzeitfähiges Verfahren, weshalb nur geringer Modifikationsaufwand zur Umsetzung des offline-Algorithmus in Echtzeit notwendig ist. Abgewandelt wird die Approximation des $1/f$ -Rauschens mittels einer Exponentialkurve. Die Anpassung kann nicht mehr anhand der gesamten Datenaufzeichnung geschehen, sondern wird iterativ mit jedem neu hinzukommenden Datensegment verfeinert. Dazu wird das ASD des ak-

tuellen Segmentes k zur Summe aller ASDs addiert und der Mittelwert bestimmt:

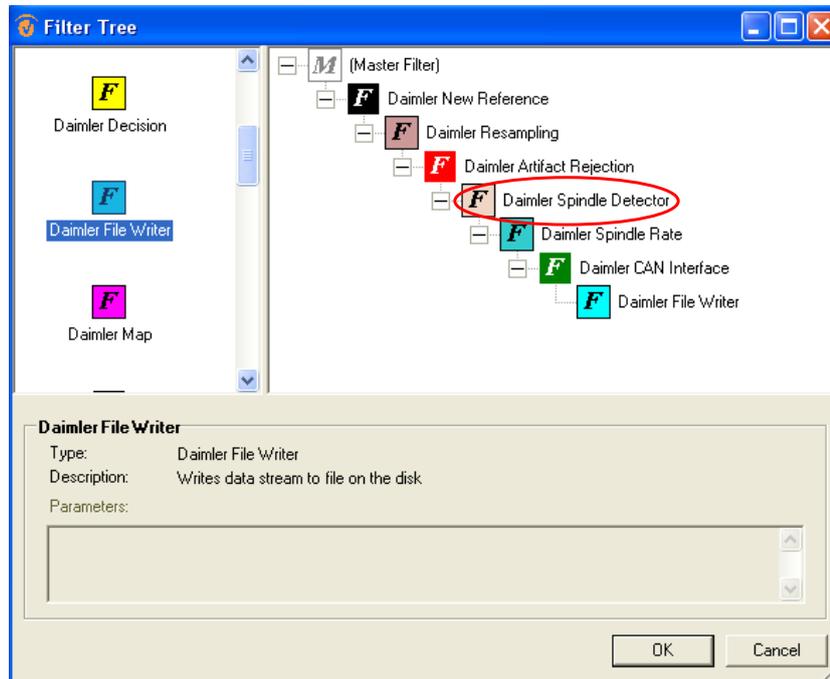
$$\overline{ASD}_k(f) = \frac{1}{k} \sum_{i=1}^k ASD_i(f) \quad (2.1)$$

Die Exponentialkurve wird anschließend an $\overline{ASD}_k(f)$ angepasst und wieder durch das Verhältnis der Gesamtleistung des aktuellen Segments und des gemittelten Spektrums skaliert. Asymptotisch sind online und offline Verfahren damit äquivalent.

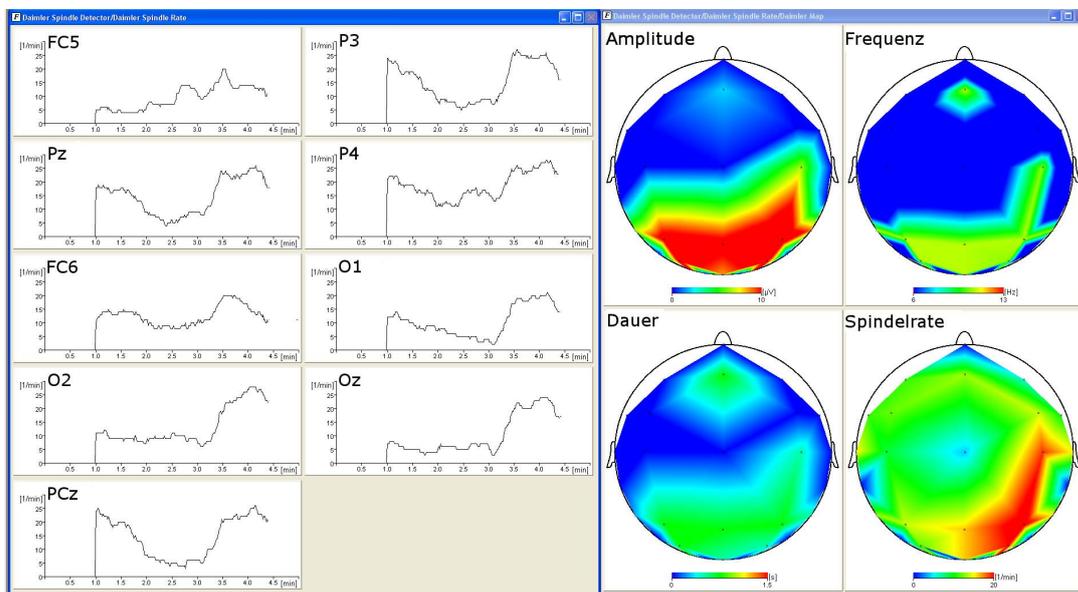
Das in den folgenden Experimenten verwendete EEG-System der Firma Brain Products verfügt über eine Softwarekomponente (*RecView*), die ein Framework zur Echtzeit-Datenanalyse der EEG-Daten beinhaltet. In diesem Framework können eigene Module (Filter) in einer .NET-Umgebung mittels C# erstellt werden. Spindeln werden nach dem oben beschriebenen Algorithmus mit einem Filter für Spindeldetektion kanalweise detektiert und als diskrete Events (Marker) mit den Eigenschaften Start- und Endzeit, Dauer, Amplitude und Frequenz an den nächsten Filter weitergegeben. Ein weiterer Filter mittelt die Spindeleigenschaften mit einem Moving Average Filter und bestimmt die Spindelrate. Einzelne Spindeln und deren Parameter sowie die Moving Average Daten können für Kanäle oder Kanalgruppen angezeigt werden. Es besteht die Möglichkeit Zeitreihen der Parameter anzuzeigen oder die topographische Verteilung der Parameter zum aktuellen Zeitpunkt zu betrachten. Eine typische Anordnung eines Filterbaumes zur online EEG-Analyse sowie Visualisierungen der Spindelparameter sind in [Abbildung 2.4](#) gezeigt. Neben dem Spindeldetektor sind u.a. Module zur Rereferenzierung der EEG-Kanäle, spektralen Filterung und Artefaktdetektion vorhanden.

2.2 Performanceanalyse

Die Performance des Detektionsverfahrens sowie dessen Anfälligkeit auf Rauschen wird anhand synthetischer EEG-Daten mit simulierten Alpha-Spindeln untersucht. Da alle Eigenschaften der simulierten Spindeln bekannt sind (Start- und Endzeit, Dauer, Amplitude und Frequenz), kann zum einen die Detektionsrate und zum anderen die Genauigkeit in der Bestimmung der Spindelparameter ermittelt werden. Darüber hinaus kann die Performance unter verschiedenen Signal-Rausch-Verhältnissen untersucht werden, indem das Hintergrundrauschen relativ zur Spindelamplitude angepasst wird.



(a)



(b)

Abbildung 2.4: (a) RecView Filterbaum zur online-Verarbeitung von EEG-Daten. Der Spindeldetektor ist rot eingekreist. (b) links: Zeitverlauf der Spindelrate an mehreren Kanälen. rechts: Topographie der aktuellen Spindelparameter.

Wie bereits erwähnt hat das Rauschen im EEG generell eine $1/f$ -Charakteristik. Es wird eine Zeitreihe mit eben dieser Eigenschaft generiert und an zufällige Positionen innerhalb der Zeitreihe werden Sinusschwingungen mit zufälliger, gleichverteilter Dauer (0,5–3,5 s), Frequenz (7,5–12,5 Hz) und Phase ($0-2\pi$) addiert. Alle Parameter werden unabhängig voneinander variiert. Die Amplitude jeder Spindel wird so zum lokalen Rauschpegel angepasst, dass sie einem zuvor definierten SNR entspricht. Start und Ende jeder Spindel wird mit einem Kosinus-Taper von 100 ms Länge multipliziert, um zum einen keine Unstetigkeiten zu erzeugen und zum anderen die typische Form der Spindeln zu simulieren.

Es werden 50 Kanäle mit je 400 Spindeln und ca. 60 min Dauer unabhängig voneinander simuliert, um verschiedene Realisationen von Rauschen zu testen. Das Signal-Rausch-Verhältnis wird mit -6 dB, -3 dB und 0 dB simuliert.

Die simulierten Daten werden mit Hilfe von ROC-Kurven (Receiver Operating Characteristic) analysiert (Fawcett, 2006). Dazu wird jede Zeitreihe, analog zum Detektionsverfahren für Spindeln, in Segmente von 1 s Dauer und 750 ms Überlappung zerlegt. Ein Segment, das zu mindestens 50% mit einer simulierten Spindel überlappt, wird zur positiven Klasse gezählt, andernfalls zur negativen. Ein Segment wird als richtig positiv (true positive) gewertet, wenn eine detektierte Spindel zu mindestens 50% mit einem Segment der positiven Klasse überlappt. Als falsch positiv (false positive) wird ein Segment gezählt, wenn eine detektierte Spindel zu mindestens 50% mit einem Segment der negativen Klasse überlappt. Die richtig-positiv-Rate (true positive rate, TPR) ist definiert als die Summe der richtig Positiven geteilt durch die Gesamtzahl positiver Segmente. Die falsch-positiv-Rate (false positive rate, FPR) ist die Summe der falsch Positiven geteilt durch die Gesamtzahl der negativen Segmente. Der Schwellwert, der zur Erstellung der ROC-Kurven variiert, ist der Oszillationsindex.

Um eine Verbindung zwischen dem SNR der simulierten Daten und dem Oszillationsindex des Spindeldetektors herzustellen, wird der mittlere Oszillationsindex aller korrekt detektierten Spindeln berechnet (s. Tabelle 2.1). Der mittlere Oszillationsindex für reale Daten aus Experiment II (s. Abschnitt 2.3.2) beträgt 3,9 ($\pm 0,6$). Demnach entspricht ein SNR von -3 dB in der Simulation (s. Tabelle 2.1) ungefähr dem zu erwartenden Rauschlevel der realen Daten.

Für ein SNR von -3 dB wird eine Sensitivität von mehr als 95% mit gleichzeitig unter 3% FPR erreicht. Abbildung 2.5 zeigt die Detektionsperformance des Algorithmus für simulierte Daten unter verschiedenen SNRs. Wie erwartet ist eine konvergierende Performancesteigerung mit zunehmendem SNR zu beobachten,

	SNR [dB]		
	-6	-3	0
Oszillationsindex	3	3,8	4,6
RMSE Frequenz [Hz]	0,06	0,05	0,04
RMSE Dauer [s]	0,21	0,19	0,18
RMSE Amplitude [a.u.]	0,003 (0,024)	0,0028 (0,033)	0,003 (0,048)

Tabelle 2.1: Genauigkeit der Parameterschätzung für simulierte Spindeln. Die mittlere Spindeldauer ist 2 s und die mittlere Spindelfrequenz 10 Hz. Da die Spindelamplitude abhängig vom SNR ist, ist der entsprechende Mittelwert in Klammern angegeben. Die Ergebnisse basieren auf 50 simulierten Kanälen mit je 400 Spindeln (RMSE - Root Mean Squared Error).

wobei ein SNR von -3 dB ungefähr dem Rauschlevel in den realen EEG-Daten entspricht.

Tabelle 2.1 vergleicht außerdem die Genauigkeit der Parameterschätzung für Spindeln bei unterschiedlichen SNRs. Hierzu wird der Root Mean Squared Error (RMSE) zwischen den geschätzten Parametern und den tatsächlichen Werten berechnet. Die Frequenz der Spindeln lässt sich sehr genau bestimmen, da der Schätzfehler für die Spindelfrequenz innerhalb der Frequenzauflösung der FFT liegt. Der Fehler bei der Berechnung der Spindeldauer rührt hauptsächlich aus dem Tapering am Start und Ende der Spindeln, wodurch dieser Bereich nicht mehr zuverlässig detektiert werden kann. Das Tapering ist allerdings notwendig, um keine Sprungstellen im Signal einzuführen. Der Schätzfehler der Spindelamplitude ist stark abhängig von Bias und Varianz der verwendeten Spektralschätzung (Oppenheim und Schafer, 1989), aber als niedrig genug einzuschätzen. Die Schätzgenauigkeit nimmt mit steigendem SNR zu, ist aber für alle SNR ausreichend groß.

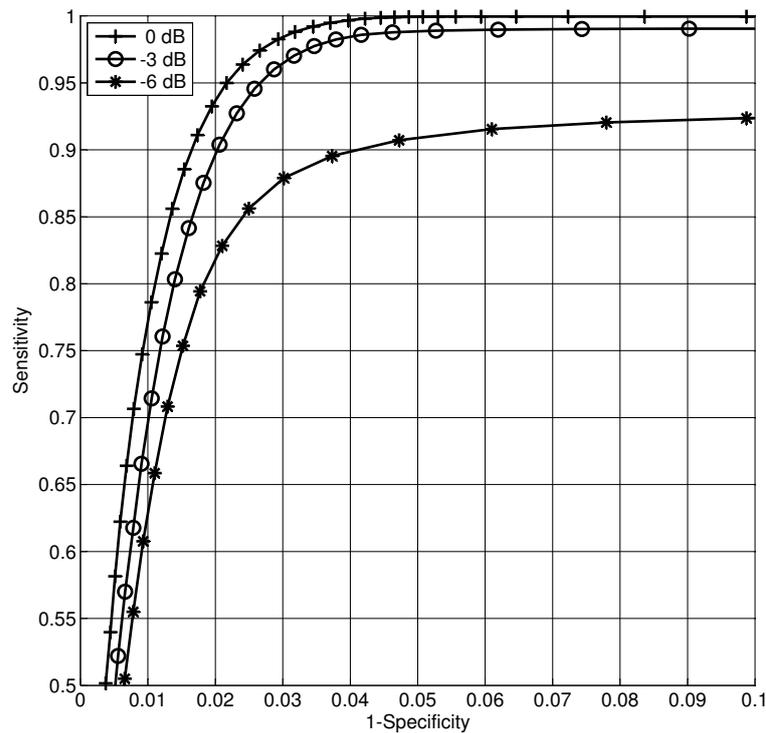


Abbildung 2.5: ROC-Kurven für die Detektionsperformance für Alpha-Spindeln bei simulierten Daten unter verschiedenen SNR.

2.3 Fahrer als Sensor (FaSor)

Das vorgestellte EEG-Maß wird in diesem Abschnitt auf seine Anwendbarkeit zur Detektion von Müdigkeit bei Autofahrern im realen Straßenverkehr untersucht. Auch wird die Eignung der Alpha-Spindeln als Müdigkeitsmaß mit den klassischen EEG-Bandleistungsmaßen verglichen. Hierzu werden im Rahmen des BMBF-Projekts FaSor (Fahrer als Sensor, Projektnummer 16SV2233) zwei monotone Tagfahrexperimente durchgeführt. Übergeordnetes Thema des Projektes ist die Entwicklung von Systemen und Verfahren zur verbesserten Interaktion zwischen Fahrer, Fahrzeug und Umfeld. Ziel des Projektes ist es, den kognitiven Zustand des Fahrers mit Hilfe physiologischer Daten in Echtzeit erfassen zu können, um sicherheitskritische Zustände wie Müdigkeit und Unaufmerksamkeit objektiv messbar zu machen. Moderne Fahrerassistenzsysteme und Fahrer bilden ein sich wechselseitig beeinflussendes System, in dem im optimalen Fall veränderte kognitive Zustände des Fahrers einen Einfluss auf die Funktion der Assistenzsysteme haben. Um dies zu erreichen, werden zum einen physiologische Sensoren (aktive

EEG-Elektroden) von der Firma Brain Products weiterentwickelt und zum anderen Verfahren zur Erkennung von verminderter kognitiver Leistungsfähigkeit im Rahmen dieser Dissertation und des Projektes FaSor entwickelt.

2.3.1 Experiment I

In diesem Experiment werden die Effekte monotoner Tagfahrten auf den Vigilanzzustand des Fahrers sowie auf seine Fähigkeit der Selbsteinschätzung anhand von physiologischen Daten, Leistungsmaßen und Befragungen untersucht. Hierzu stehen die Daten von 29 Probanden (Mitarbeiter der Daimler AG) zur Verfügung. Auf Grund technischer Probleme bei einigen Versuchsfahrten und weiterer Ausschlußkriterien reduziert sich die Stichprobe auf 22, wovon drei den Versuch wegen starker Ermüdung frühzeitig abgebrochen haben. Die Probanden sind angewiesen in der Nacht vor dem Experiment ausreichend zu schlafen und am Morgen des Versuchs keinen Kaffee zu trinken.

Das Experiment wird in einer Mercedes-Benz S-Klasse (W221) mit Automatikschaltung durchgeführt, ausgestattet mit EEG-Hardware, PCs zur Erfassung der Fahrzeugdaten und mehreren IR-Kameras, welche sowohl den Fahrer, den Innenraum als auch das Fahrgeschehen vor und hinter dem Fahrzeug erfassen (s. Abbildung 2.6). Die Fahrt wird stets von einem Versuchsleiter begleitet. Dieser hat die Aufgabe den Fahrer kontinuierlich zu überwachen und bei starker Übermüdung den Versuch abubrechen. Mit Hilfe einer Kamera auf dem Armaturenbrett kann der Versuchsleiter das Gesicht des Fahrers beobachten, um bei eindeutigen Anzeichen von Müdigkeit (z.B. deutlich verlängerte Lidschlusszeiten) den Versuch abubrechen und ggf. mittels einer eingebauten Zweitpedalerie (vergleichbar mit der eines Fahrschulfahrzeugs) einzugreifen. Ein Eingriff des Versuchsleiters war aber bei keiner der Versuchsfahrten notwendig, da der Abbruch jeweils von den Probanden selbst initiiert wurde. Das Experiment besteht aus freiem Fahren auf der Autobahn mit einer Höchstgeschwindigkeit von 130 km/h, ohne die Nutzung von Assistenzsystemen wie Tempomat und automatischer Abstandsregelung. Um Bewegungsartefakte im EEG zu reduzieren und die Monotonie der Fahrt zu erhöhen, dürfen keine fahrirrelevanten Bedienhandlungen erfolgen (Radio, Navigationssystem, Klimaanlage). Unterhaltungen mit dem Versuchsleiter sind untersagt.

Die Teststrecke verläuft auf der wenig befahrenen Autobahn A81 von Ehningen bis Gottmadingen mit 3 Wendepunkten innerhalb der Strecke (s. Abbildung 2.7). Der Versuch dauert ca. 4 Stunden und hat eine Gesamtlänge von ca. 430 km. Alle



Abbildung 2.6: Fotos: Versuchsträger mit Messrechnern und Kameras; Proband mit EEG und Taster für die Zweitaufgabe

Fahrten beginnen um 12:45 Uhr, um zirkadiane Effekte konstant zu halten und enden um ca. 17 Uhr. Die Probanden werden darauf hingewiesen, dass sie den Versuch jederzeit abbrechen können, wenn sie sich zu müde zum Weiterfahren fühlen.

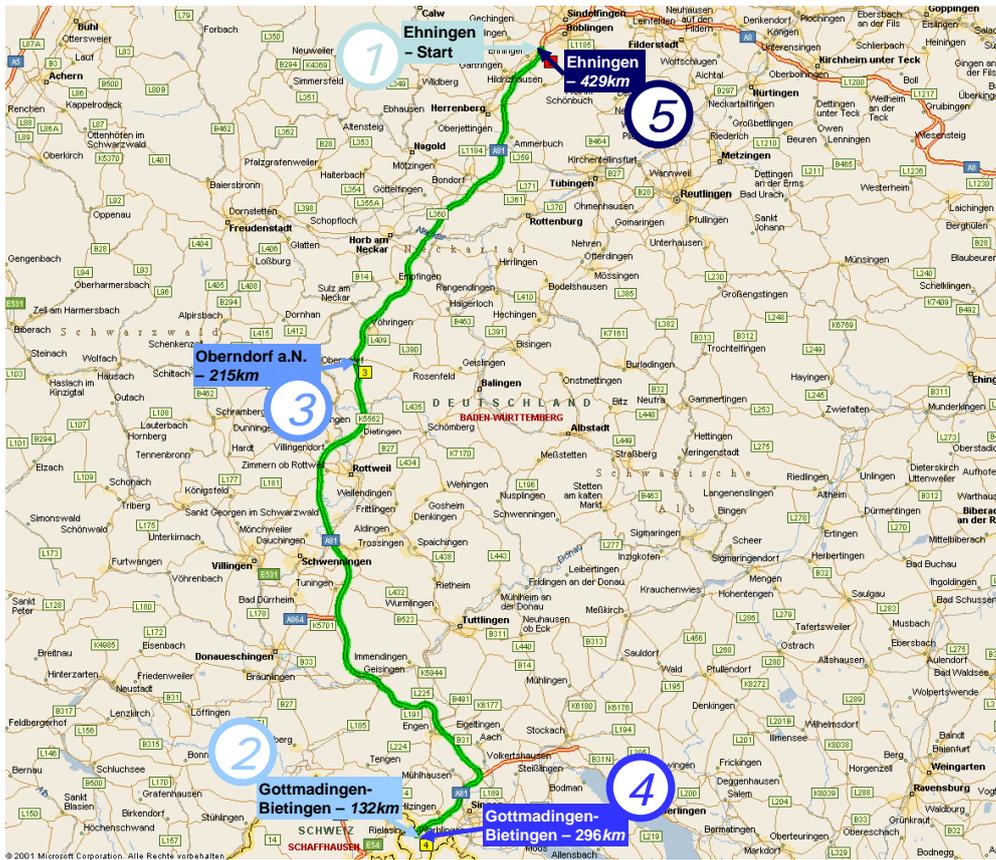


Abbildung 2.7: Versuchsstrecke für beide Tagfahrexperimente. Beziffert sind: 1) Startpunkt, 2-4) Wendepunkte, 5) Endpunkt.

Während der Fahrt wird alle 20 min die subjektiv empfundene Müdigkeit mit Hilfe der Karolinska Sleepiness Scale erfasst (KSS, Åkerstedt und Gillberg, 1990). Außerdem üben die Probanden ein auditorisches Oddball als Zweitaufgabe aus, um zum einen Reaktionszeiten als Leistungsmaß und zum anderen ereigniskorrelierte Potentiale (P300) aus dem EEG als physiologischen Müdigkeitsindikator erfassen zu können. Die Zweitaufgabe besteht aus häufigen, irrelevanten Tönen mit einer Frequenz von 500 Hz und seltenen Zieltönen mit 400 Hz, auf die durch drücken eines Tasters am rechten Daumen möglichst schnell und nur wenn es die Verkehrssituation erlaubt, reagiert werden muss.

Die EEG-, EOG- und EKG-Signale des Probanden werden mit einem 128-Elektroden-System (acticap) und BrainAmp-Verstärkern der Firma Brain Products GmbH mit 1000 Hz Abtastrate aufgezeichnet. Die Elektroden sind auf Basis des erweiterten internationalen 10-20 Systems angeordnet und monopolar zum Nasion referenziert. Aus dem EEG wird die Alpha-Spindelrate an Pz und die P300 Amplitude des ereigniskorrelierten Potentials an CPz berechnet. Mit dem EKG wird die Herzrate bestimmt. Die Hypothese ist, dass alle objektiven Maße (Spindelrate, P300, Herzrate und Reaktionszeiten) eine Reduktion der Vigilanz mit gefahrener Strecke zeigen. Der Verlauf der Selbsteinschätzung (KSS) wird experimentell überprüft und mit den objektiven Maßen verglichen.

Ergebnisse

Eine ausführlichere Beschreibung dieser Studie (s. Abbildung 2.9) und deren Resultate findet sich auch bei Schmidt et al. (2009). Analysiert werden die Daten der 19 Probanden, die die gesamte Strecke gefahren sind und keine technischen Probleme aufweisen. Abbildung 2.8 zeigt den Verlauf aller Maße über die gefahrene Strecke. Die Werte stellen Mittelwerte über einen Streckenabschnitt von 107 km dar, was einem Viertel der Gesamtstrecke entspricht. Alle objektiven Maße (Abbildung 2.8b - 2.8e) weisen einen linearen Trend auf, wobei die Richtung des Trends auf eine Vigilanzabnahme hindeutet. Da mehrere unabhängig erhobene Maße, welche zudem unterschiedliche Messdimensionen abbilden (Verhalten, vegetatives Nervensystem, kognitive Leistungsfähigkeit), auf die gleiche Entwicklung mit gefahrener Strecke hindeuten, sind diese Ergebnisse als valide und zuverlässig anzusehen. Einzig in der Selbsteinschätzung der Müdigkeit kommt es nach anfänglicher Zunahme der Müdigkeit gegen Ende der Fahrt zu einer subjektiven Erholung. Es ist anzunehmen, dass der Widerspruch zwischen objektiven Maßen und subjektiver Einschätzung gegen Ende der Fahrt aus einer verminderten Fähigkeit der Selbsteinschätzung resultiert. Die abweichende Selbsteinschätzung kann durch die veränderte zirkadiane Phase, erhöhte Verkehrsdichte zum Streckenende hin (und damit einhergehend eine geringere Monotonie) oder die Erwartung, dass die Fahrt bald vorüber ist, hervorgerufen werden. Auf Basis der physiologischen Daten ist anzunehmen, dass die höhere Selbsteinschätzung im letzten Fahrtabschnitt eine Überschätzung der eigenen Leistungsfähigkeit darstellt, was das Fortsetzen der Fahrt in einem sicherheitskritischen Zustand zur Folge haben kann.

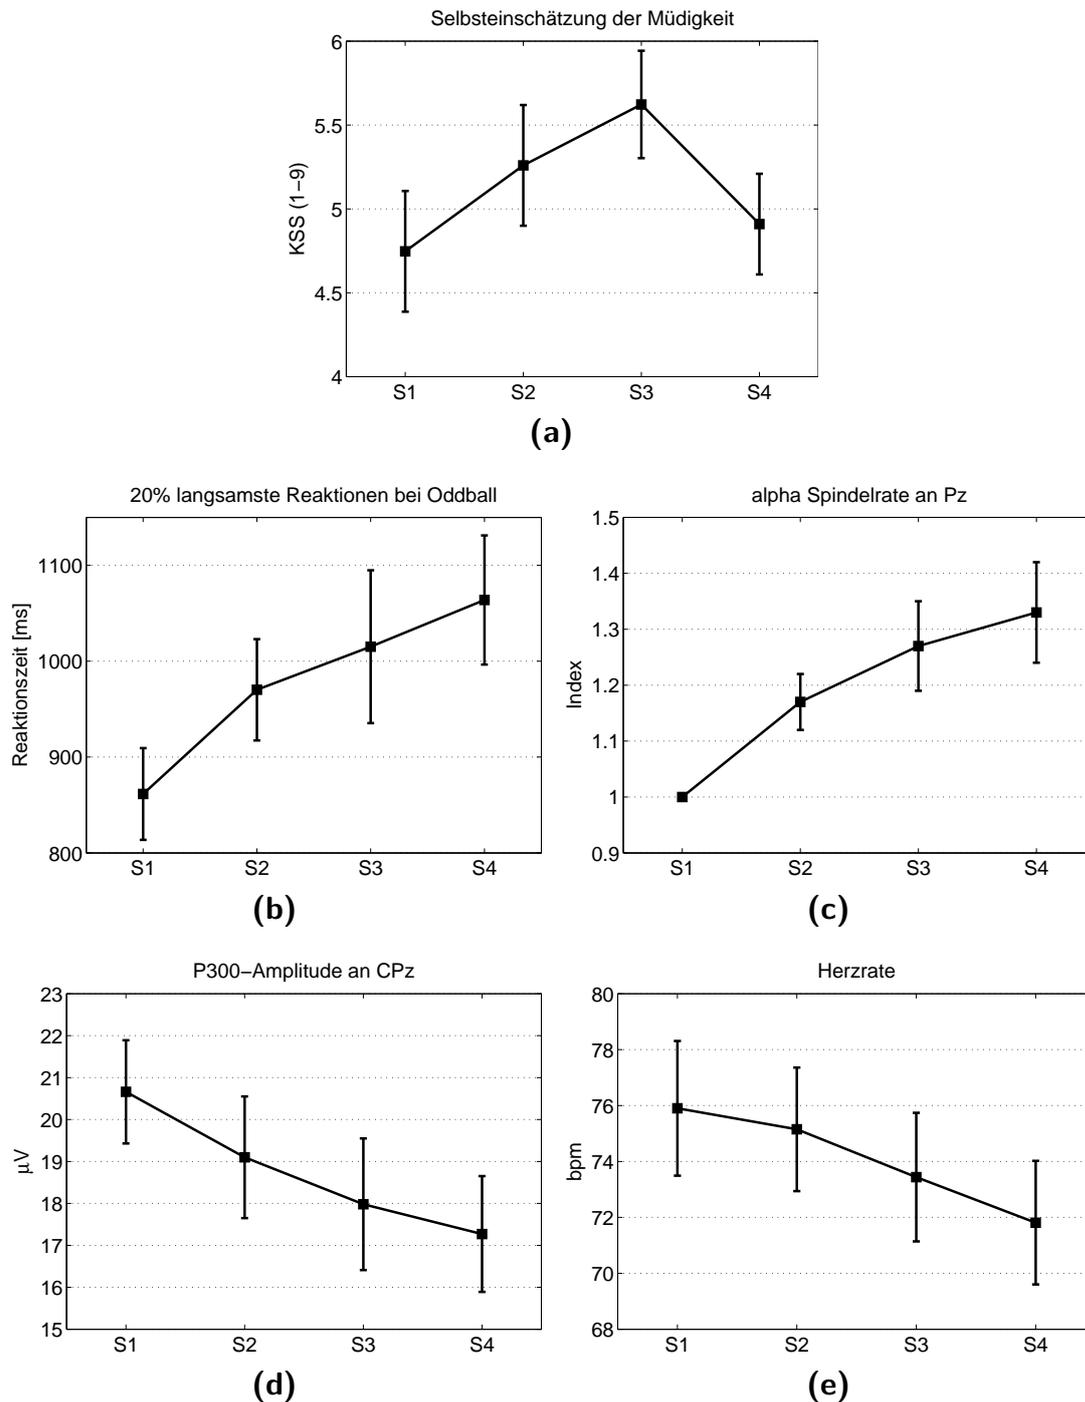


Abbildung 2.8: Ergebnisse des ersten Experiments. Veränderungen subjektiver und objektiver Maße der Streckenabschnitte S1 bis S4 bei einer monotonen Tagfahrt. Alle objektiven Maße deuten auf eine kontinuierliche Verschlechterung des Zustandes des Fahrers hin. Die Probanden empfinden allerdings eine subjektive Erholung am Ende der Fahrt.

2.3.2 Experiment II

In einer zweiten Erhebung wird die gleiche Teststrecke verwendet, allerdings unterscheiden sich die Wendepunkte zum ersten Experiment und auch innerhalb dieses Experimentes wurden verschiedene Wendepunkte genutzt. Es existieren zwei Strecken mit unterschiedlichen Wendepunkten, um streckenbezogene Effekte ausschließen zu können. Beide Strecken haben eine Länge von ca. 480 km. Des Weiteren wird die Zweitaufgabe dahingehend abgeändert, dass nun nicht mehr nur auf den seltenen Ton reagiert werden muss, sondern mit einem zusätzlichen Taster an der anderen Hand auch auf den häufigen Ton (Verhältnis häufig zu selten: 80/20). Darüber hinaus wird mit den Daten dieses Experiments in einer Veröffentlichung von (Schmidt et al., 2011) der Effekt der Abfrage (KSS) auf verschiedene Vigilanzindikatoren untersucht. Alpha-Spindelrate, Blinzeldauer der Augen und Herzrate zeigen eine signifikante Verbesserung der Vigilanz während der Kommunikationsphase verglichen mit einer Baseline vor der Abfrage. Die Aktivierung hält bis etwa 2 min nach der Befragung an. Vor Beginn der Fahrt wird zusätzlich ein Versuch im Fahrsimulator von ca. 1,5 Stunden Dauer durchgeführt, welcher in Abschnitt 2.4 ausführlich beschrieben ist.

Für diesen Versuch werden 30 Probanden aus der Belegschaft der Daimler AG rekrutiert. Alle Probanden stammen aus unterschiedlichen Abteilungen und nehmen freiwillig am Versuch teil. Somit ist kein Zwang zur Teilnahme über die Aufforderung von Vorgesetzten möglich. Der Ablauf des Experimentes ist ähnlich zu Experiment I, um die Vergleichbarkeit zu gewährleisten. Der Versuch beginnt wieder um 12:45 Uhr und dauert ca. 4 Stunden. Als Versuchsstrecke wird ebenfalls die A81 verwendet. Eine ausführliche Beschreibung des Versuch findet sich auch bei Schmidt et al. (2011). Vier Datensätze müssen auf Grund technischer Probleme von der weiteren Analyse ausgeschlossen werden. Auf Grund starker Übermüdung brechen sieben Probanden den Versuch vorzeitig ab.

Zur Aufzeichnung des EEG wird ein acticap EEG-System mit BrainAmp-Verstärker der Firma Brain Products GmbH verwendet. Es werden 64 Elektroden mit 500 Hz Abtastrate eingesetzt. Referenz ist wie in Experiment I der Nasenrücken.

2.3.3 Abbrecher

Wie Experiment I gezeigt hat, ist die Selbsteinschätzung der Probanden nicht immer zuverlässig und daher als Referenz für Müdigkeit weniger geeignet. Wie bereits

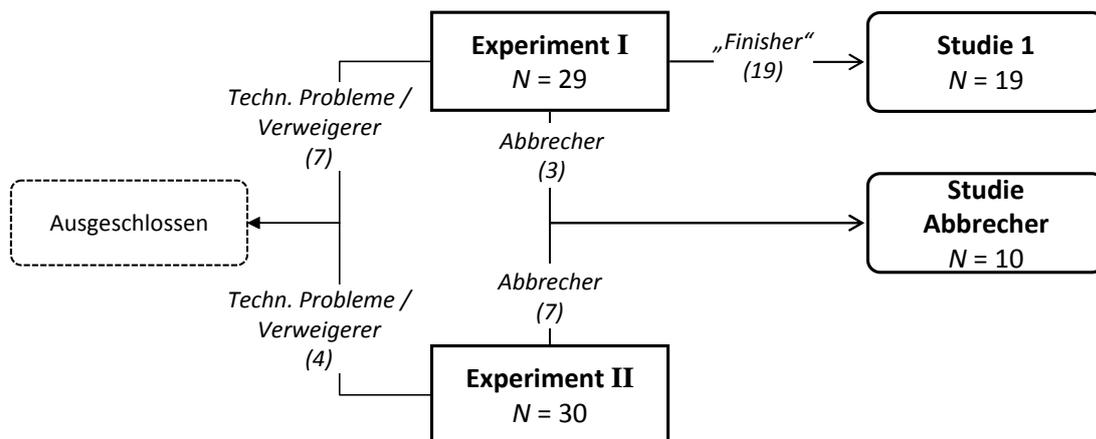


Abbildung 2.9: Übersicht über erfasste Daten in den beiden Tagfahrexperimenten und Zusammensetzung der Stichproben für die zwei vorgestellten Studien (adaptiert aus Schmidt, 2010, mit Genehmigung).

geschildert haben in Experiment I drei Probanden und in Experiment II sieben Probanden den Versuch wegen Übermüdung freiwillig abgebrochen. Der Abbruch stellt das objektivste zur Verfügung stehende Müdigkeitskriterium dar. In den folgenden Analysen werden deshalb nur die Daten der Abbrecher genauer untersucht. Mit diesem Kriterium werden zum einen die Alpha-Spindeln hinsichtlich ihrer Eignung als Müdigkeitsmaß untersucht und zum anderen die Alpha-Spindeln mit klassischen EEG-Maßen verglichen. Da die Alpha-Power in der Literatur der am häufigsten verwendete Indikator für Vigilanzabnahmen im Fahrkontext ist, wird dieses Maß mit den Spindelparametern verglichen. Eine Übersicht über die Stichprobengrößen der einzelnen Experimente und deren Aufteilung ist in Abbildung 2.9 dargestellt.

Die durchschnittliche Fahrtdauer der 10 Abbrecher (6 männlich, 4 weiblich, Alter: Mittelwert = 27,5 Jahre; Spanne: 24–36) beträgt 2:23 h (Standardabweichung: 0:38 h; Spanne: 0:56–3:15 h). Um einen maximalen Kontrast zwischen wachen und müden Fahrtabschnitten zu erzielen, wird ein Abschnitt zu Beginn der Fahrt mit einem Abschnitt kurz vor Abbruch verglichen. Es ist plausibel anzunehmen, dass die Fahrer zu Beginn wach sind, da das Experiment am Tag, mit ausgeruhten Probanden stattfindet. Die KSS bestätigt diese Annahme, welche einen Wert von durchschnittlich 4,3 ($\sigma = 1,9$) in den ersten 20 min und 8,5 ($\sigma = 0,5$) in den letzten 20 min hat. Deshalb werden die ersten und letzten 20 min einer Fahrt als Vergleich zwischen wachen und müden Fahrtabschnitten verwendet. Nach der Entscheidung

die Fahrt abzurechnen vergehen noch einige Minuten, bis eine Autobahnausfahrt erreicht wird. In dieser Phase unterhalten sich Proband und Versuchsleiter, um eine weitere Ermüdung zu verhindern. Da hier meist eine kurzfristige Erholung des Probanden erfolgt, werden bei allen Datensätzen die letzten fünf Minuten einer Fahrt nicht berücksichtigt, um eine Verfälschung der Ergebnisse zu vermeiden. Der zweite 20 min Abschnitt endet demnach 5 min vor dem eigentlichen Ende der Fahrt.

Für die Analyse der Abbrecher werden alle 64 Elektroden aus Experiment I verwendet, die mit Elektroden aus Experiment II korrespondieren. Alle Datensätze werden Bandpass-gefiltert zwischen 0,5 Hz und 48 Hz und anschließend unterabgetastet auf 128 Hz. Der extended infomax ICA Algorithmus (EEGLab Toolbox, [Delorme und Makeig, 2004](#)) wird verwendet, um EEG-Daten in den Quellenraum zu transformieren. Dort werden Komponenten, die Artefakten durch Augenbewegungen, Muskelaktivität oder technischen Störungen entsprechen, entfernt und die Daten wieder in den Signalraum rücktransformiert. Besonders Muskelaktivität ist häufig über viele Komponenten verteilt, welche auch neuronale Aktivität enthalten ([Halder et al., 2007](#); [McMenamin et al., 2010](#)). Deshalb ist es nicht möglich die Daten von allen Artefakten zu bereinigen. Stattdessen werden Segmente mit verbliebenen Artefakten mit dem in Kapitel 4 beschriebenen Artefakt-detektor identifiziert und von der weiteren Analyse ausgeschlossen. Temporale und fronto-polare Elektroden werden auf Grund ihrer Nähe zu muskulären Strukturen gänzlich ausgeschlossen. Damit stehen 43 von 62 EEG-Elektroden zur Analyse bereit. Die Kanäle Cz und FC2 müssen wegen technischer Störungen ebenfalls ausgelassen werden.

2.3.3.1 Statistische Methoden

Der bereits beschriebene Algorithmus zur Detektion von Alpha-Spindeln wird verwendet, um die Parameter Spindelrate, -amplitude, -dauer und -frequenz für jeden Kanal zu berechnen. Alle Parameter werden in den jeweiligen 20 min Abschnitten gemittelt. Die Alpha-Power (7–13 Hz) wird kanalweise für beide Abschnitte mit dem Welch-Periodogramm mit 32 s Fensterlänge und 50% Überlappung berechnet ([Oppenheim und Schafer, 1989](#)). Jede Messgröße ist in 3 Kanalgruppen (frontal, zentral und parieto-okzipital, s. Tabelle 2.2) zusammengefasst und der Mittelwert der Daten pro Gruppe wird berechnet. Für jeden Parameter resultieren 6 Werte je Proband, welche mit einer zweifaktoriellen MANOVA mit Messwiederholung für

jeden Parameter mit den Innersubjektfaktoren *Fahrtabschnitt* und *Kanalgruppe* analysiert werden. Es wird eine multivariate Varianzanalyse (MANOVA) verwendet, um Probleme bei Verletzung der Sphärizitätsannahme (gleiche Varianz aller Faktorstufen, gleiche Korrelation zwischen den Faktorstufen) zu vermeiden. Sphärizität (Auch: Varianzhomogenität; gleiche Varianzen in allen Faktorstufen) ist für einen multivariaten Ansatz keine notwendige Voraussetzung (O'Brien und Kaiser, 1985). Die berichtete Testgröße ist der exakte F-Wert, beruhend auf Pillais Spur. Für alle Analysen wird eine Irrtumswahrscheinlichkeit von 0,05 angesetzt. Bei Ablehnung der H_0 ist das partielle η^2 als Maß der Effektgröße angegeben. Für statistisch signifikante Effekte des Faktors *Kanalgruppe* wird eine post-hoc Analyse durchgeführt, bei der jede Faktorstufe mit der vorherigen verglichen wird, um zu untersuchen inwieweit es signifikante Unterschiede zwischen benachbarten Kanalgruppen gibt.

		Kanalgruppen		
		frontal	zentral	parieto- okzipital
Kanäle	F3, F1, Fz, F2, F4, FC3, FC1, FCz, FC4	C3, C1, C2, C4, CP3, CP1, CPz, CP2, CP4	P3, P1, Pz, P2, P4, PO3, POz, PO4, O1, Oz, O2	

Tabelle 2.2: Übersicht über die Kanalgruppen

2.3.3.2 Ergebnisse

Die Ergebnisse der Varianzanalyse mit Messwiederholung für die Faktoren *Fahrtabschnitt* und *Kanalgruppe* der Abbrecher sind in Tabelle 2.3 zusammengefasst. Abbildung 2.10 zeigt die Mittelwerte über alle Abbrecher für die beiden abhängigen Variablen.

Alle Maße außer Spindelfrequenz zeigen signifikante Unterschiede ($p < 0,05$) zwischen den ersten und letzten Fahrtabschnitten. Spindelrate, -dauer und -amplitude zeigen die deutlichsten Unterschiede, verdeutlicht in den partiellen η^2 -Werten, mit dem höchsten Wert von 0,715 für Spindelrate.

Nur die Spindelfrequenz weist signifikante Effekte für die Kanalgruppen auf. Frontale Kanäle haben eine niedrigere Frequenz als zentrale ($F(1,9) = 20,55$;

	Haupteffekt					
	Fahrabschnitt			Kanalgruppe		
	F(1,9)	p	η^2	F(2,8)	p	η^2
Spindelrate	22,56	0,001	0,72	0,80	0,481	n.s.
Spindeldauer	21,28	0,001	0,70	1,05	0,393	n.s.
Spindelamplitude	9,67	0,013	0,52	1,57	0,266	n.s.
Spindelfrequenz	0,04	0,849	n.s.	16,20	0,002	0,80
Alpha-Power	8,18	0,019	0,48	1,41	0,299	n.s.

(a) Haupteffekte für die Faktoren Fahrabschnitt und Kanalgruppe

	Interaktion		
	F(2,8)	p	η^2
Spindelrate	0,54	0,601	n.s.
Spindeldauer	0,65	0,550	n.s.
Spindelamplitude	0,58	0,581	n.s.
Spindelfrequenz	0,60	0,572	n.s.
Alpha-Power	0,48	0,638	n.s.

(b) Interaktion der Faktoren Fahrabschnitt und Kanalgruppe**Tabelle 2.3:** Ergebnisse der MANOVA mit Messwiederholung für die Parameter der Alpha-Spindeln und Alpha-Power.

$p = 0,001$; $\eta^2 = 0,695$) und zentrale wiederum niedrigere Frequenzen als parieto-okzipitale Kanäle ($F(1,9) = 19,62$; $p = 0,002$; $\eta^2 = 0,686$). Abbildungen 2.10a - 2.10e weisen, durch eine höhere Spindelrate und längere Spindeldauer, auf eine erhöhte Alpha-Aktivität von anterior nach posterior hin. Dieser Effekt ist allerdings für beide Variablen nicht signifikant.

Weder für die Spindelmaße noch für die Alpha-Power ist eine signifikante Interaktion zwischen den Faktoren Fahrabschnitt und Kanalgruppe feststellbar. Demnach sind gleiche Effekte für alle Kanalgruppen bei steigender Müdigkeit zu erwarten.

Betrachtet man den relativen Anstieg der Müdigkeitsmaße zwischen dem ersten und letzten Abschnitt der Fahrt, so zeigt die Spindelrate, mit ca. 90% Anstieg im letzten relativ zum ersten Fahrtsegment, den größten Dynamikumfang (Abbildung 2.11). Die Alpha-Power steigt hier nur um ca. 32%.

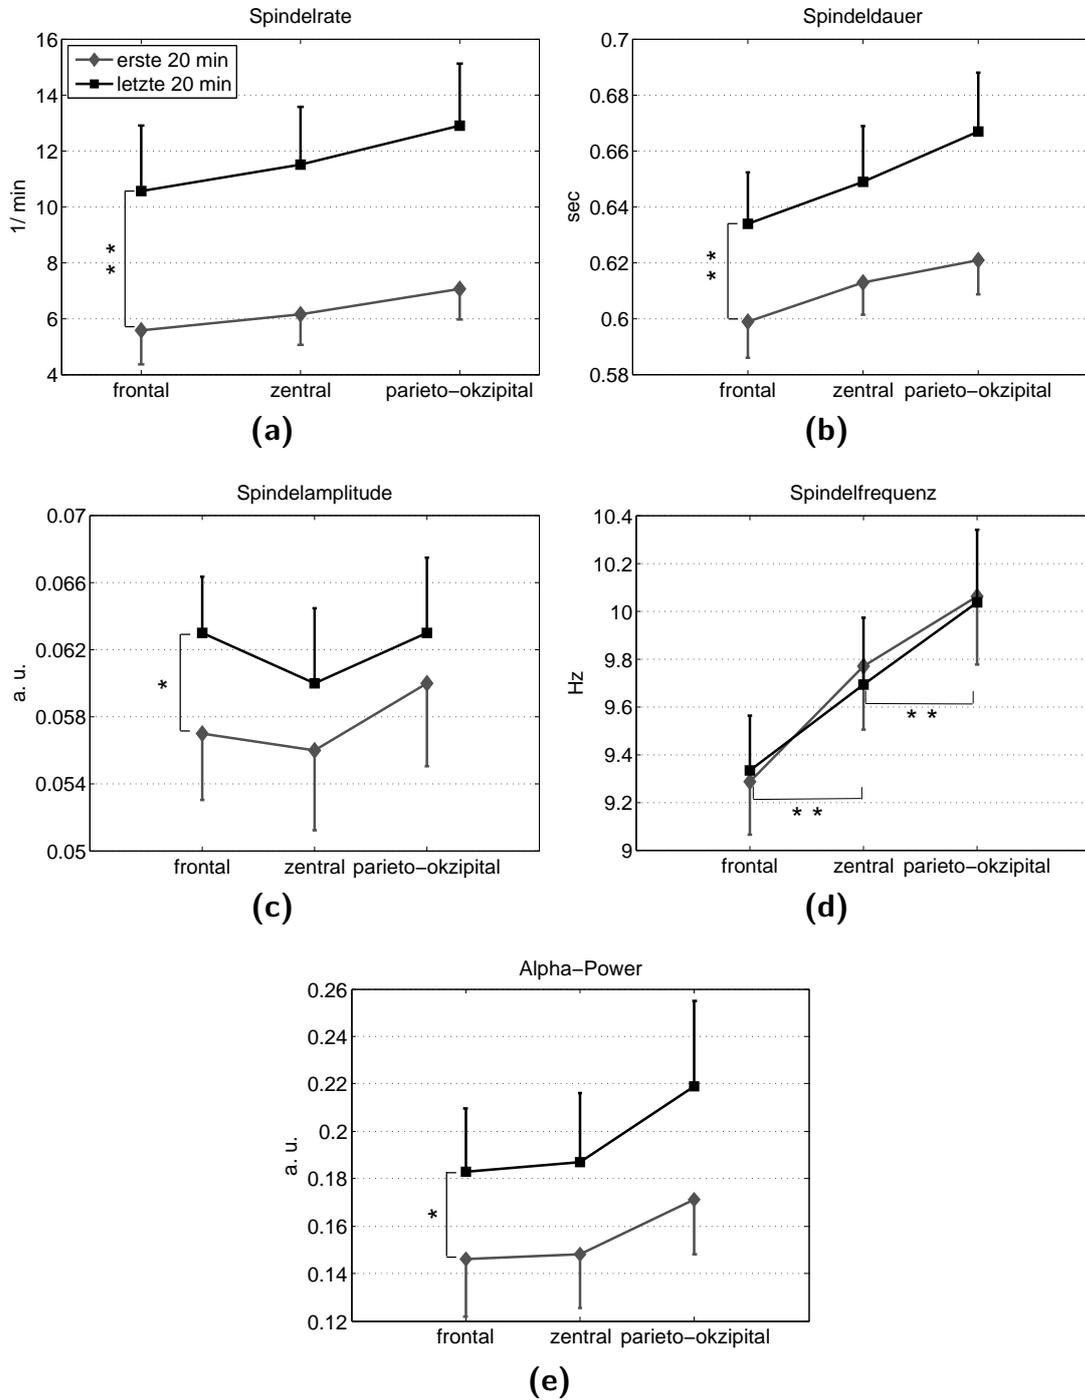


Abbildung 2.10: Vergleich des ersten und letzten Fahrtschnitts für drei Kanalgruppen. Dargestellt sind Mittelwerte über alle Probanden. Fehlerbalken zeigen die Standardfehler der Mittelwerte (* $p < 0,05$; ** $p < 0,01$).

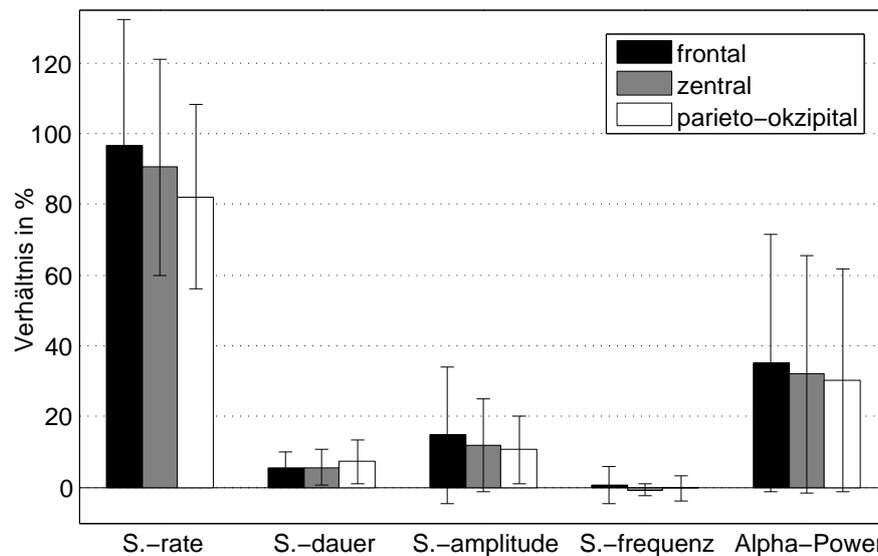


Abbildung 2.11: Relativer Anstieg der untersuchten Maße (S.-Spindel) vom ersten zum letzten Fahrtabschnitt in %.

Vergleich Abbrecher / Nicht-Abbrecher

Bei dem vorgestellten experimentellen Setup lässt es sich nicht vermeiden, dass neben dem Faktor Müdigkeit auch ein Effekt in den abhängigen Variablen durch die reine Dauer der Aufgabe (time-on-task) zu vermuten ist, es also zu Veränderungen in den Messgrößen bereits durch diesen time-on-task Effekt kommt. Damit sind beide Faktoren bei der Untersuchung einer Versuchsperson nicht voneinander unterscheidbar. In der Tat bestätigt die Studie von [Schmidt et al. \(2009\)](#), dass bei monotonen Tagfahrten, die nicht auf Grund erhöhter Müdigkeit abgebrochen wurden time-on-task Effekte u.a. bei der Spindelrate zu beobachten sind. Um den Einfluss von starker Ermüdung, welche schließlich zum Abbruch der Fahrt führt von reinen time-on-task Effekten unterscheiden zu können, werden die Daten der Personen, die die Fahrt des oben beschriebenen Experiments nicht abgebrochen haben herangezogen. Wenn die abhängigen Variablen tatsächlich sensitiv für Müdigkeit sind, so müssen neben signifikanten Effekten des Faktors time-on-task für die Abbrecher zusätzlich Effekte durch die erhöhte Müdigkeit beobachtbar sein, welche für die Nicht-Abbrecher fehlen oder geringer ausfallen.

Es stehen 31 valide Datensätze der Nicht-Abbrecher zur Verfügung. Die Dauer der Fahrten für die Nicht-Abbrecher wird auf eine Länge äquivalent der Abbrecher reduziert, um den time-on-task Effekt vergleichbar zu halten. Die verschiedenen

Fahrtauern der Abbrecher sind normalverteilt mit einem Mittelwert von 2:23 h und einer Standardabweichung von 38 min. Die Fahrtdauer jedes Nicht-Abbrechers wird auf eine zufällige Länge begrenzt, indem eine Zufallszahl aus genannter Normalverteilung gezogen wird und der Fahrtdauer des Nicht-Abbrechers zugeordnet wird.

Es werden nur diejenigen Messgrößen aus vorheriger Analyse verwendet, die signifikante müdigkeitsbedingte Effekte zeigen (alle außer Spindelfrequenz). Es wird wieder der Mittelwert jedes Parameters in den ersten und letzten 20 min berechnet, diesmal gemittelt über alle Kanäle, da keine Effekte der Kanalgruppen zu beobachten sind. Zur Analyse wird wieder eine zweifaktorielle Varianzanalyse mit Messwiederholung, in Form einer MANOVA, verwendet, mit dem Innersubjektfaktor *Fahrtabschnitt* und dem Zwischensubjektfaktor *Abbruch*. Die Ergebnisse sind in Tabelle 2.4 und Abbildung 2.12 präsentiert.

	Haupteffekt					
	Fahrtabschnitt			Abbruch		
	F(1,39)	p	η^2	F(1,39)	p	η^2
Spindelrate	58,95	<0,001	0,60	11,56	0,002	0,23
Spindelamplitude	17,96	<0,001	0,32	0,01	0,923	n.s.
Spindeldauer	34,45	<0,001	0,47	11,33	0,002	0,23
Alpha-Power	11,52	0,002	0,23	0,141	0,710	n.s.

(a) Haupteffekte für die Faktoren Fahrtabschnitt und Abbruch

	Interaktion		
	F(1,39)	p	η^2
Spindelrate	8,30	0,006	0,18
Spindelamplitude	8,54	0,006	0,18
Spindeldauer	6,65	0,014	0,15
Alpha-Power	3,52	0,068	n.s.

(b) Interaktion der Faktoren Fahrtabschnitt und Abbruch

Tabelle 2.4: Ergebnisse der MANOVA mit Messwiederholung für den Vergleich von Abbrechern und Nicht-Abbrechern mit dem Innersubjektfaktor Fahrtabschnitt und dem Zwischensubjektfaktor Abbruch.

Die Varianzanalyse zeigt signifikante Innersubjekteffekte des Faktors *Fahrtabschnitt* für alle abhängigen Variablen, d.h. die ersten 20 min der Fahrt unterscheiden sich sowohl für Abbrecher als auch für Nicht-Abbrecher von den letzten 20 min. Weiterhin ist eine signifikante Interaktion zwischen Fahrtabschnitt und Probandengruppe für Spindelrate, -amplitude und -dauer zu beobachten. Im Detail bedeutet dies einen stärkeren Anstieg genannter Variablen vom ersten zum letzten Fahrtabschnitt für die Abbrecher. Spindelrate und -dauer zeigen zusätzlich einen signifikanten Zwischensubjekteffekt, mit höheren Werten für die Abbrecher, unabhängig vom Fahrtabschnitt.

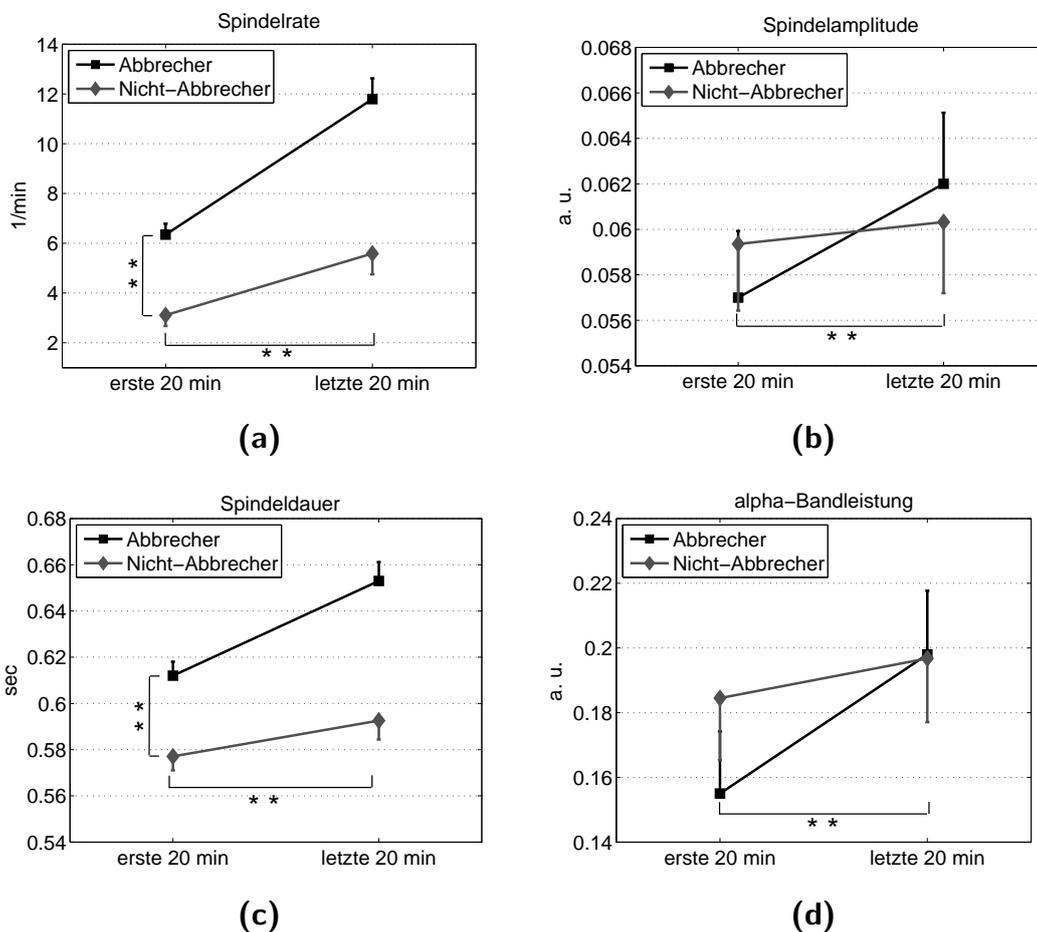


Abbildung 2.12: Gruppenmittelwerte der Messgrößen für den Vergleich von Abbrechern und Nicht-Abbrechern. Fehlerbalken zeigen die Standardfehler der Mittelwerte (* $p < 0,05$; ** $p < 0,01$).

Zeitauflösung der Müdigkeitsindikatoren

Bisher werden alle Müdigkeitsmaße für die Analysen jeweils in 20 min-Abschnitten gemittelt, da nur für diese grobe Zeiteinteilung eine verlässliche Aussage über die tatsächliche Müdigkeit getroffen werden kann. Ein Müdigkeitsmaß sollte aber eine zeitliche Auflösung besitzen, die der realen Fluktuation der Müdigkeit entspricht. Um diesen Punkt zu adressieren, werden die Müdigkeitsmaße der Abbrecher in Fenstern von 1 bis 10 min Länge für beide Fahrtabschnitte berechnet. Alle Fenster der ersten 20 min werden als wach definiert und alle Fenster der letzten 20 min als müde. Die Spindelrate, mit den höchsten zu erwartenden Effekten, wird mit der Alpha-Power verglichen. Um die diskriminativen Eigenschaften verschiedenen langer Fenster zu untersuchen, wird eine ROC-Analyse durchgeführt. Dabei wird angenommen, dass der Grad der Müdigkeit innerhalb der beiden Fahrtabschnitte konstant ist, bzw. Schwankungen unterliegt, die relativ zu den Unterschieden zwischen den Fahrtabschnitten klein sind. Die Sensitivität (true positive rate) ist definiert als die Anzahl richtig positiver Fenster (positive Klasse: letzte 20 min) geteilt durch die Gesamtanzahl von Fenstern der letzten 20 min. Die Spezifität (1-FPR) ist die Anzahl falsch positiver Fenster (ein Fenster der ersten 20 min, das als müde klassifiziert wird) geteilt durch die Gesamtzahl an Fenstern des ersten Abschnitts.

Beide Maße werden pro Kanal in überlappenden Fenstern von 1 bis 10 min Dauer mit 10s Schrittweite berechnet. Um die Daten aller Abbrecher zusammenfassen zu können, müssen die Daten vorher normiert werden, da die Probanden unterschiedliche Mittelwerte und Varianzen haben. Bei der Normierung sollte das Verhältnis zwischen den Kanälen nicht verändert werden. Deshalb wird für jedes Zeitfenster der Mittelwert über alle Kanäle abgezogen und anschließend durch die Standardabweichung aller Kanäle dividiert. Da keine signifikanten Unterschiede zwischen den Kanälen existieren (s. Tabelle 2.3), werden Spindelrate und Alpha-Power pro Fenster über alle Kanäle gemittelt. Die ROC-Kurven sind durch die Variation eines Schwellwertes für Spindelrate und Alpha-Power erzeugt, welcher über die Zugehörigkeit zu müden oder wachen Abschnitten entscheidet.

Abbildung 2.13 zeigt die ROC-Kurven der Spindelrate für Fensterlängen von 1 bis 10 min und in Tabelle 2.5 sind die zugehörigen AUC-Werte (area under curve, Fawcett, 2006) für Spindelrate und Alpha-Power aufgelistet. Alle Fensterlängen sind in der Lage die beiden Müdigkeitsniveaus zu unterscheiden, allerdings mit unterschiedlicher Qualität. Wie anzunehmen war, verbessert sich die Perfor-

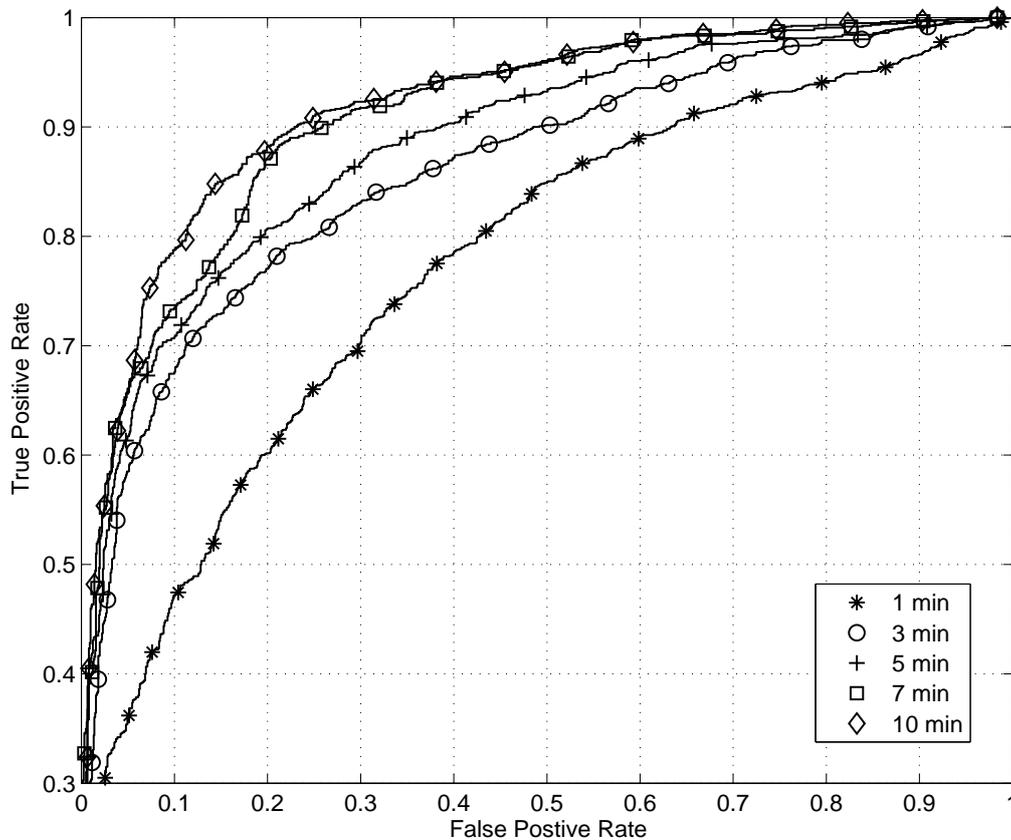


Abbildung 2.13: ROC Analyse der Spindelrate, berechnet für verschiedene Fensterlängen im ersten und letzten Fahrtabschnitt.

mance mit zunehmender Fensterlänge, bei gleichzeitiger Reduktion der zeitlichen Auflösung. Besonders von 1 min zu 3 min Fensterlänge ist für die Spindelrate ein deutlicher Sprung in der Performance sichtbar. Die Alpha-Power zeigt nur bis 3 min Fensterlänge eine Verbesserung, mit generell niedrigeren AUC-Werten als die Spindelrate (s. Tabelle 2.5).

2.3.3.3 Diskussion

Anhand simulierter Daten kann gezeigt werden, dass der FFT-basierte Spindeldektektor eine gute Detektionsperformance zeigt und die Genauigkeit beim Schätzen der Spindelparameter ebenfalls gute Ergebnisse liefert. Durch die Approximation des Rauschlevels mit einer Exponentialkurve kann der Oszillationsindex in den Experimentaldaten auf 3,9 ($\sigma=0,6$) geschätzt werden, was einem SNR von -3 dB

Fensterlänge	1 min	3 min	5 min	7 min	10 min
Spindelrate	0,775	0,862	0,886	0,911	0,921
Alpha-Power	0,764	0,799	0,801	0,796	0,784

Tabelle 2.5: Vergleich der AUC-Werte für Spindelrate und Alpha-Power für jede Fensterlänge.

für die simulierten Daten entspricht. Weiterhin ist die vorgestellte Methode besser geeignet Müdigkeit aus im Realverkehr aufgenommenen EEG-Daten zu identifizieren, als die häufig in der Literatur verwendete Leistung im Alpha-Band.

In der Studie von [Schmidt et al. \(2009\)](#) wird die Fähigkeit der Selbsteinschätzung von Müdigkeit mittels KSS in Frage gestellt. Auch in dieser Studie kommt eine Form von Selbsteinschätzung zum Einsatz, nämlich die Selbstbeurteilung des Probanden nicht mehr fahrtüchtig zu sein, was einen Abbruch der Fahrt zur Folge hat. Es wird damit implizit angenommen, dass ein sehr hoher Grad von Müdigkeit sehr wohl richtig wahrgenommen wird. Diese Art der Selbstbeurteilung hat sich bereits in mehreren Studien als zuverlässig und objektivierbar herausgestellt ([Lisper et al., 1986](#); [Reyner und Horne, 1998](#); [Horne und Baulk, 2004](#)). Die scheinbar schlechtere Fähigkeit zur Selbsteinschätzung in der Studie von [Schmidt et al. \(2009\)](#) ist eher darauf zurückzuführen, dass die Probanden hier eine generell geringere Müdigkeit in relativ feinen Abstufungen zu bewerten haben. Ferner kann für diese Studie in allen 10 Fällen eines Fahrtabbruchs der Eindruck starker Fahrerermüdung durch den Versuchsleiter bestätigt werden.

Die statistischen Analysen der EEG-Daten im Realverkehr ergeben signifikante Zunahmen aller Spindelparameter (außer Spindelfrequenz) zwischen den ersten und letzten 20 min der Fahrt. Die Effektstärken der Spindelparameter sind generell höher als die der Alpha-Power, welche ebenfalls einen signifikanten Anstieg zeigt (s. Tabelle 2.3). Dies bestätigt die Hypothese, dass Alpha-Spindeln ein sensiblerer Indikator für Müdigkeit sind als Alpha-Power, insbesondere bei Messungen außerhalb des Labors. Auf Gruppenebene ergeben sich signifikante Effekte für alle untersuchten Kanalgruppen (frontal, zentral, parieto-okzipital, Tabelle 2.2), ohne dass sich eine Region als besonders sensitiv herausstellt. In der Literatur sind häufig abweichende Ergebnisse zu finden, welche hauptsächlich von Effekten an zentralen und parietalen, aber nicht frontalen Elektroden berichten ([Lal und Craig, 2001](#); [Oken et al., 2006](#)). Eine mögliche Erklärung für die abweichenden Er-

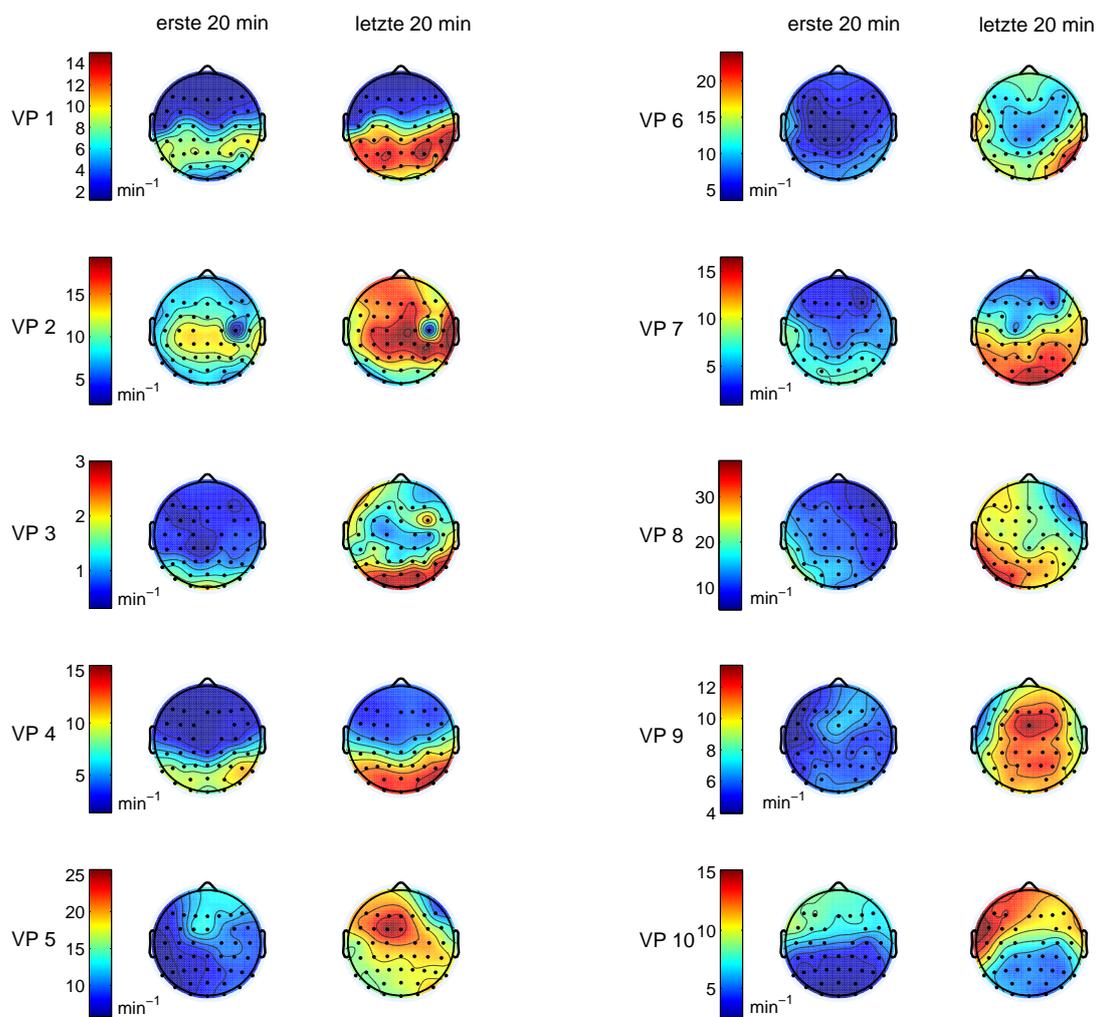


Abbildung 2.14: Topographie der Alpha-Spindelrate gemittelt über die ersten und letzten 20 min der Fahrt für alle Abbrecher. Auffällig ist die starke interindividuelle Variation der Spindelaktivität. C4 bei VP2 ist defekt.

gebnisse in dieser Studie ist die unterschiedliche Definition der Grenzfrequenzen für das Alpha-Band. So werden z.B. müdigkeitsbedingte Effekte für das Theta-Band mit 8 Hz als obere Bandgrenze an frontalen Elektroden berichtet (Lal und Craig, 2002; Strijkstra et al., 2003), was schon zu einer Überlappung von 1 Hz mit der hier verwendeten Definition des Alpha-Bandes führt. Eine genaue Abgrenzung der Theta- und Alpha-Aktivität ist im Kontext dieser Arbeit problematisch, da beide mit Müdigkeit korrelieren. Für eine exakte Trennung der Rhythmen wären individuell definierte Bandgrenzen nötig. Eine mögliche Vermischung der Rhythmen in der Analyse ist für die Beurteilung von Müdigkeit weniger relevant, da sowohl Theta- als auch Alpha-Aktivität mit Müdigkeit korrelieren und in der Richtung der Effekte übereinstimmen. Eine weitere Erklärung für müdigkeitsbedingte Effekte in allen Kanalgruppen kann die starke interindividuelle Variation der Spindelaktivität sein (s. Abbildung 2.14). Schwerpunkte der Spindelaktivität reichen von parieto-okzipital bis frontal. Auf Gruppenebene kann es dadurch signifikante Beiträge in allen Kanalgruppen geben, wobei nur Probanden in der jeweiligen Kanalgruppe zum Effekt beitragen, welche dort auch eine ausgeprägte Spindelaktivität aufweisen. Insgesamt stimmen die hier gefundenen Ergebnisse mit vergleichbaren Studien zum Thema Müdigkeit beim Autofahren überein (s. Tabelle 1.1). Abweichungen in Teilergebnissen können durch unterschiedliche experimentelle Bedingungen, wie die Verwendung von Fahrsimulatoren oder Experimente mit schlafdeprivierten Probanden entstehen.

Der Vergleich der Spindelparameter zwischen den Abbrechern und den Nicht-Abbrechern bestätigt die Fähigkeit der Alpha-Spindeln kritische Zustände von Müdigkeit zu identifizieren. Ein signifikanter Effekt des Faktors *Fahrtabschnitt* (time-on-task) war zu erwarten, da er vermischt ist mit der zunehmenden Müdigkeit und auch ohne nennenswerte Müdigkeit bei den Nicht-Abbrechern auftritt. Daher ist die signifikante Interaktion (s. Tabelle 2.4) zwischen den Faktoren *Fahrtabschnitt* und *Abbruch* hier entscheidend. Diese zeigt deutlich, dass für Abbrecher ein stärkerer Anstieg in den Spindelparametern (Rate und Dauer) zu erwarten ist, der zusätzlich zum time-on-task Effekt auftritt und eben genau diese sicherheitskritische Müdigkeit darstellt, welche letztendlich zum Fahrtabbruch in dieser Probandengruppe führt. Spindelrate und -dauer ermöglichen also die Diskriminierung zwischen einem time-on-task Effekt und kritischer Müdigkeit. Ein Zweistichproben t-Test für die ersten 20 min verdeutlicht außerdem, dass Spindelrate ($T(39) = 3,41, p = 0,002$) und Spindeldauer ($T(39) = 2,93, p = 0,006$) bereits in dieser frühen Phase der Fahrt Abbrecher von Nicht-Abbrechern unterscheiden

können. Mit Hilfe der Alpha-Power ist dies nicht möglich. Zu ähnlichen Ergebnissen kommt auch eine Studie von [Otmani et al. \(2005\)](#), in der schlafdeprivierte Probanden von einer Kontrollgruppe zu Beginn eines Simulatorexperiments nicht anhand von Theta- oder Alpha-Aktivität unterschieden werden kann. Die Ursache für die stärkere und früher beginnende Ermüdung der Abbrecher bleibt unklar. Es gibt keine Berichte von chronischen Schlafstörungen und alle Probanden gaben an in der Nacht zuvor ausreichend geschlafen zu haben. Mögliche Ursachen können eine schlechte Schlafqualität in den Nächten zuvor sein oder eine generell höhere Anfälligkeit auf passive aufgabenbezogene Müdigkeit, insbesondere bei monotonen Aufgaben. Unabhängig von den genauen Ursachen lassen sich mit den Alpha-Spindeln bereits früh Probanden mit erhöhter Müdigkeit identifizieren.

Die ROC-Analyse der zeitlichen Auflösung der Spindelrate zeigt einen Kompromiss zwischen Performance und Zeitauflösung (s. [Abbildung 2.13](#)). Die bessere Performance für längere Zeitfenster ist auf die geringere Varianz dieser Daten zurückzuführen. Dies hat zwei Ursachen: Zum einen findet in längeren Zeitfenstern eine stärkere Mittelung des Signals statt, was die Varianz reduziert, zum anderen sind in der Definition eines gesamten 20 min Abschnittes als entweder „wach“ oder „müde“ Kurzzeitvariationen der Müdigkeit nicht berücksichtigt, was durch feinere Zeitauflösung detektierbar wird. Längere Zeitfenster entsprechen also der hier verwendeten Gruppierung von 20 min Blöcken per se besser. Leider ist eine genauere zeitliche Beschreibung der Müdigkeit in diesem Experiment nicht möglich. Für das vorliegende Anwendungsgebiet erscheint eine Zeitauflösung von 3 bis 5 min als ein guter Kompromiss. Zu erwähnen sei noch, dass die Performanceverbesserung für längere Fenster für Alpha-Bandleistung nicht auftritt.

In die vorangegangenen Analysen sind nur klar definierte Müdigkeitszustände zu Beginn und Ende der Fahrt eingegangen. In [Abbildung 2.15](#) ist auch die Entwicklung der Spindelrate und Alpha-Power zwischen diesen Zuständen dargestellt. Aufgetragen ist hier der Mittelwert über alle Abbrecher, unterteilt in 5 Segmente, welche abhängig von der Fahrtdauer in ihrer Länge variieren. Die Spindelrate zeigt einen nahezu linearen Verlauf mit geringen Standardabweichungen. Die Alpha-Power hingegen hat einen wesentlich geringeren Anstieg über die Zeit und weniger konsistente Verläufe zwischen den Probanden, was an den höheren Standardabweichungen erkennbar ist. Um die Unterschiede im linearen Trend zwischen den beiden Messgrößen genauer zu quantifizieren, wird eine lineare Regression für beide Maße berechnet. Wie aus [Abbildung 2.15](#) bereits vermutet werden kann, hat die Spindelrate einen stärkeren linearen Trend ($b = 5,35$, $F(1, 48) = 48,85$,

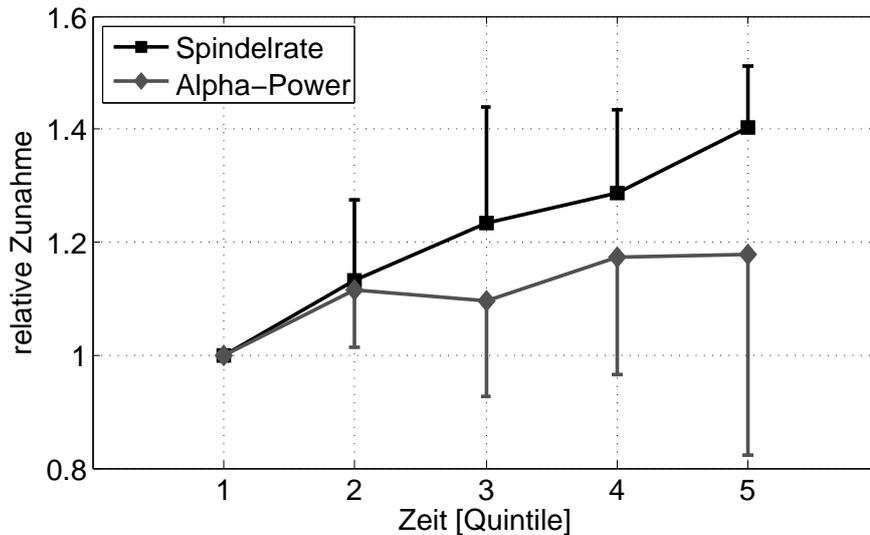


Abbildung 2.15: Zeitliche Entwicklung der Spindelrate und Alpha-Power gemittelt über alle Abbrecher. Aufgrund der unterschiedlichen Fahrtauern wird die Zeit je Proband in fünf gleichlange Segmente (Quintile) unterteilt. Segmente zwei bis fünf werden zum ersten Segment referenziert (1.0 entspricht 100%). Für jeden Probanden wird der Mittelwert über alle Kanäle verwendet. Die Fehlerbalken zeigen die Standardabweichungen.

$p < 0,001$, $R^2 = 0,504$) als die Alpha-Power ($b = 2,85$, $F(1,48) = 11,26$, $p = 0,0016$, $R^2 = 0,19$).

Detaillierte Vergleiche zwischen den hier vorgestellten Alpha-Spindeln und klassischen Bandleistungsmaßen sind aus Gründen der Übersichtlichkeit bisher auf das Alpha-Band begrenzt, da es das am weitesten verbreitete EEG-Müdigkeitsmaß in der Literatur ist. Da auch andere Bänder in der Literatur Verwendung finden, sind hier kurz Ergebnisse für das Delta-, Theta- und Beta-Band sowie das Verhältnis (Alpha+Theta)/Beta vorgestellt. Es wird die gleiche statistische Analyse wie in Abschnitt 2.3.3.1 durchgeführt. Die Ergebnisse sind in Tabelle 2.6 zusammengefasst. Keines der Bänder zeigt eine signifikante Veränderung mit dem Faktor Fahrtabschnitt. Dies bestätigt, dass von den klassischen EEG-Bändern das Alpha-Band am besten für Müdigkeitsuntersuchungen im Realverkehr geeignet scheint. Zu gleichen Ergebnissen kommen auch mehrere andere Studien (E. J. Caille, 1977; O’Hanlon und Kelley, 1977; Kecklund und Åkerstedt, 1993; Lin et al., 2005).

	Haupteffekt					
	Fahrabschnitt			Kanalgruppe		
	F(1,9)	p	η^2	F(2,8)	p	η^2
Theta	0,790	0,397	n.s.	1,842	0,220	n.s.
Beta	3,534	0,093	n.s.	2,334	0,159	n.s.
Delta	0,575	0,468	n.s.	3,287	0,091	n.s.
(Alpha+Theta)/ Beta	2,528	0,146	n.s.	0,698	0,525	n.s.

(a) Haupteffekte für die Faktoren Fahrabschnitt und Abbruch

	Interaktion		
	F(2,8)	p	η^2
Theta	2,064	0,189	n.s.
Beta	1,937	0,206	n.s.
Delta	0,222	0,806	n.s.
(Alpha+Theta)/ Beta	4,547	0,048	0,532

(b) Interaktion der Faktoren Fahrabschnitt und Kanalgruppe**Tabelle 2.6:** Ergebnisse der MANOVA mit Messwiederholung für weitere EEG-Bänder.

2.3.4 Relation zwischen EEG und Fahrverhalten

Wie bereits in der Einleitung (s. Abschnitt 1.2.3) erwähnt, existieren verschiedene Ansätze Müdigkeit auf Basis von Veränderungen im Fahrverhalten zu bestimmen. Dies ist naheliegend, da sich die negativen Auswirkungen von Müdigkeit auf z.B. Aufmerksamkeit und Reaktionsvermögen letztlich auf die Fähigkeit ein Fahrzeug zu führen auswirken und sich damit das Unfallrisiko erhöht. Unklar ist inwieweit die im vorangegangenen Abschnitt erläuterten Alpha-Spindeln einen Zusammenhang mit Parametern des Fahrverhaltens aufweisen. Ein solcher ist anzunehmen, da sowohl EEG-Parameter als auch das Führen des Fahrzeugs von Müdigkeit beeinflusst werden, allerdings ist die Stärke des Zusammenhangs nicht bekannt, jedoch von Interesse. Unterschiede in den Ausprägungen der Merkmale hinsichtlich Müdigkeit sind anzunehmen, da beide Messverfahren von verschiedenen Störquellen und unbekanntem Variablen beeinflusst werden.

Müdigkeitsbedingte Veränderungen im Fahrverhalten werden im Folgenden durch das Mercedes-Benz System „Attention Assist“ quantifiziert. Dieses Verfahren ist, im Gegensatz zu anderen fahrzeugbezogenen Maßen, speziell für Fahrten im Realverkehr bzw. für den kommerziellen Einsatz entwickelt worden und damit besonders geeignet für die vorliegenden Experimente, welche ausschließlich im normalen Straßenverkehr durchgeführt wurden.

Wie in der Einleitung bereits angedeutet, werden beim „Attention Assist“ bestimmte Lenkmuster detektiert, welche in Verbindung mit Müdigkeit gehäuft auftreten. Diese Lenkmuster bestehen aus einer Lenkruhephase mit geringer Lenkaktivität, unmittelbar gefolgt von einer Lenkkorrektur (s. Abbildung 2.16). Für das Verfahren kann sowohl der Lenkradwinkel als auch die Lenkgeschwindigkeit zur Detektion von Lenkereignissen herangezogen werden. Die folgenden Erläuterungen beziehen sich auf die Lenkgeschwindigkeit und sind den Patenten Galley et al. (2006a) und Galley et al. (2006b) entnommen. Eine weitere Erläuterung des Systems mit einer Evaluation zusätzlicher Fahrzeugparameter findet sich in Friedrichs und Yang (2010b). Die Lenkruhephase ist definiert als ein Signalabschnitt mit einer Mindestdauer von θ_{Ruhe_t} , in der die Lenkgeschwindigkeit einen Schwellwert θ_{Ruhe} nicht überschreitet. Die Lenkkorrektur ist definiert als eine unmittelbar daran anschließende Lenkbewegung in eine Richtung, bis die Lenkgeschwindigkeit erstmals Null wird, d.h. die die Bewegung in diese Richtung stoppt. Dabei muss die Lenkgeschwindigkeit einen Schwellwert θ_{Event} , mit $\theta_{Event} > \theta_{Ruhe}$, überschreiten.

Um die o.g. Parameter auf die Charakteristika jedes einzelnen Fahrers zu ad-

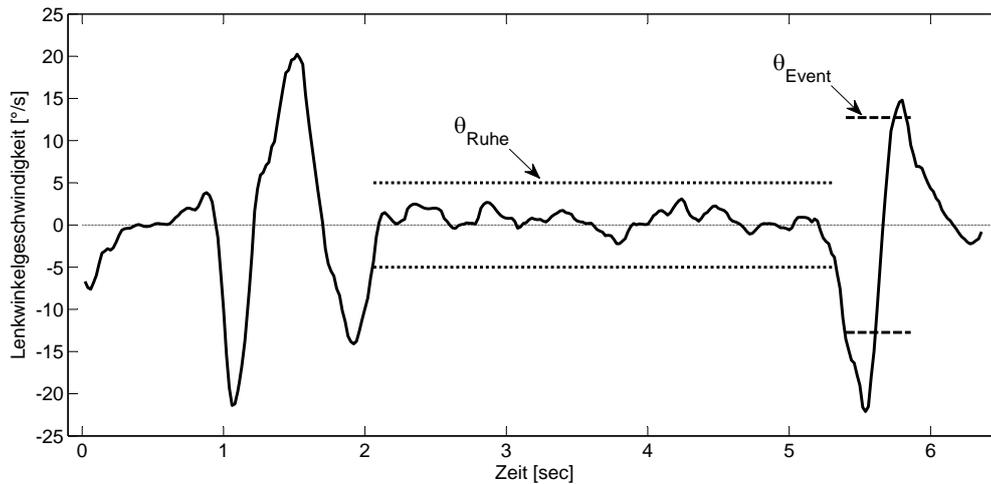


Abbildung 2.16: Lenkereignis des Attention Assist. Eine Ruhephase (Lenkaussetzer) ist gefolgt von einer ausgeprägten Lenkkorrektur. θ_{Ruhe} und θ_{Event} sind die in der Baseline ermittelten Schwellwerte zur Detektion eines Lenkereignisses (s. Text).

aptieren, wird eine Phase zu Beginn der Fahrt, in der der Fahrer noch wach ist, verwendet, um alle Schwellwerte zu bestimmen. Diese Baseline kann z.B. 20 min betragen. Für diesen Fahrtabschnitt wird jeweils die maximale Lenkgeschwindigkeit zwischen zwei Nulldurchgängen berechnet. Weiterhin wird für diese Werte das 25%- und 75%-Quartil approximiert. Das 25%-Quartil ist dabei das arithmetische Mittel aller Wert kleiner als der Mittelwert und das 75%-Quartil ist das arithmetische Mittel aller Wert größer als der Mittelwert. θ_{Ruhe} wird auf den Wert des so ermittelten 25%-Quartils gesetzt und θ_{Event} auf den Wert des 75%-Quartils. Der Zeitschwellwert θ_{Ruhe_t} wird unter Verwendung des zuvor ermittelten θ_{Ruhe} bestimmt. Dazu wird das 75%-Quartil der Dauer der Lenkruhephasen in der Baseline bestimmt. θ_{Ruhe_t} wird anschließend auf diesen Wert festgelegt.

Eine weitere wichtige Komponente des Algorithmus, welche im Patent [Galley et al. \(2006c\)](#) beschrieben ist, besteht in der Identifikation invalider Zeitbereiche, in denen Lenkereignisse generiert werden können, die nicht mit Müdigkeit in Zusammenhang stehen. Solche Lenkereignisse können durch externe Anregungen des Lenkrades durch z.B. Seitenwind, Aquaplaning oder Bodenwellen hervorgerufen werden. Weiterhin kann durch Ablenkung des Fahrers auf Grund von Bedienhandlungen (Bedienung des Radios oder Navigationsgerätes) ein Lenkereignis erzeugt werden. Und schließlich ist die Detektion müdigkeitsrelevanter Lenkereignisse in hochdynamischen Fahrsituationen nicht mehr möglich. Dazu zählen Überholmanöver sowie starke Längs- und Querschleunigungen. Da das System für den Ein-

satz auf Autobahnen bestimmt ist, wird nur im Geschwindigkeitsbereich zwischen 80 km/h und 180 km/h nach Lenkereignissen gesucht.

Die Lenkereignisse werden mit Hilfe eines exponentiell gewichteten gleitenden Mittelwertes (exponential moving average, EWMA) in eine Rate ähnlich der Spindelrate umgewandelt. Um die Vergleichbarkeit zwischen EEG-Parametern und Daten des „Attention Assist“ zu gewährleisten, wird die Spindelrate ebenfalls mit einem EWMA anstatt eines normalen gleitenden Mittelwertes berechnet. Änderungen in der Signalform ergeben sich hierbei primär lokal, Trends und globale Extrema bleiben hingegen erhalten.

Die Ergebnisse des „Attention Assist“ beruhen auf einer von mir vorgenommenen Matlab-Implementierung anhand der drei o.g. Patente. Abweichungen vom Algorithmus des Serienproduktes sind deshalb nicht auszuschließen. Auf Grund unvollständiger Fahrzeug-Daten sind nicht alle invaliden Zeitbereiche identifizierbar. Insbesondere betrifft dies Bodenwellen, Aquaplaning und Seitenwind.

Die Patente beschreiben weiterhin eine Gewichtung jedes Lenkereignisses mit müdigkeitsbedingenden Faktoren wie Tageszeit und Fahrdauer. Wenn auch plausibel für den praktischen Einsatz, sind in meiner Implementierung des Verfahrens diese Gewichtungsfaktoren nicht enthalten, da primär ein Vergleich der „Rohwerte“ von Spindelmerkmalen und Lenkereignissen von Interesse ist. Die Hinzunahme von zeitabhängigen Gewichten zu beiden Merkmalsklassen würde die Korrelation künstlich erhöhen, da eine identische Trendkomponente zu beiden Zeitreihen addiert wird, jedoch nichts über die wahren Zusammenhänge zwischen EEG-Parametern und Fahrzeugdaten aussagen.

Um die Stärke des Zusammenhangs zwischen EEG- und Fahrzeugdaten zu quantifizieren, werden Korrelationskoeffizienten zwischen z.B. der Spindelrate und der Rate der Lenkereignisse für jeden Probanden berechnet. Die „mittlere“ Korrelation für die gesamte Stichprobe der Probanden wird nach einem Verfahren von R.A. Fisher bestimmt (Fisher, 1954) und ist im Folgenden kurz dargestellt. Empirische Korrelationskoeffizienten r aus mehreren Stichproben können nicht direkt gemittelt werden, da sie keine additiven Größen sind. Stattdessen müssen die Koeffizienten mit Hilfe einer Transformation zuvor in additive Variablen umgewandelt werden. Fisher hat hierzu die nach ihm benannte Fisher-Transformation entwickelt

$$z = \frac{1}{2} \ln \frac{1+r}{1-r}. \quad (2.2)$$

Die Transformation wird weiterhin dazu verwendet verschiedene Hypothesentests

bzgl. des Korrelationskoeffizienten durchzuführen, da sie die nicht-normalverteilte Größe r in eine normalverteilte Größe z umwandelt, mit welcher Standardfehler und Konfidenzintervalle bestimmt werden können. Die Varianz von z ist unabhängig vom Erwartungswert und ergibt sich zu $Var(z) = 1/(n - 3)$, wobei n die Stichprobengröße für die Berechnung des Korrelationskoeffizienten ist. Zur Berechnung der „mittleren“ Korrelation schlägt Fisher einen gewichteten Mittelwert der transformierten Werte z_i vor, bei dem jedes z_i mit dem inversen der Varianz gewichtet wird:

$$\bar{z} = \frac{(n_1 - 3)z_1 + (n_2 - 3)z_2 + \dots + (n_N - 3)z_N}{n_1 + n_2 + \dots + n_N - 3N}. \quad (2.3)$$

Die Varianz dieses Mittelwerts ist

$$Var(\bar{z}) = \frac{1}{n_1 + n_2 + \dots + n_N - 3N}. \quad (2.4)$$

Damit kann ein $(1 - \alpha)\%$ -Konfidenzintervall CI für \bar{z} bestimmt werden:

$$CI = \bar{z} \pm z_{\alpha/2} \sqrt{Var(\bar{z})}, \quad (2.5)$$

mit dem Quantil der Standardnormalverteilung $z_{\alpha/2}$. Abschließend werden \bar{z} und CI über

$$r = \frac{\exp 2z - 1}{\exp 2z + 1} \quad (2.6)$$

rücktransformiert.

Als Datengrundlage für die folgende Analyse dient das zuvor beschriebene Fazor-Experiment. In diesem Versuch wurden sowohl EEG- als auch Fahrzeugdaten synchron aufgezeichnet. Zu den relevanten CAN-Daten gehören u.a. der Lenkradwinkel, Geschwindigkeit, Längs- und Querbefleunigung, Bedienaktivität (Blinker-, Wischerhebel, Radio, etc.) und die Fahrbahnspur (analysiert mit Hilfe einer Videokamera). Für die Analyse wird wieder eine Unterscheidung zwischen Abbrechern und Nicht-Abbrechern getroffen, um eventuelle Unterschiede in den Korrelationen zwischen beiden Gruppen zu untersuchen. Damit stehen 10 Abbrecher und 31 Nicht-Abbrecher zur Verfügung. Exemplarisch für die Spindelmerkmale wird eine Korrelation der Spindelrate mit der Rate der Lenkereignisse berechnet, da die Spindelrate sich als vielversprechendstes Merkmal in den vorangegangenen Analysen herausgestellt hat. In Abbildung 2.17 sind die mittleren Korrelationskoeffizienten für beide Probandengruppen und drei Kanalgruppen getrennt dargestellt. Für die

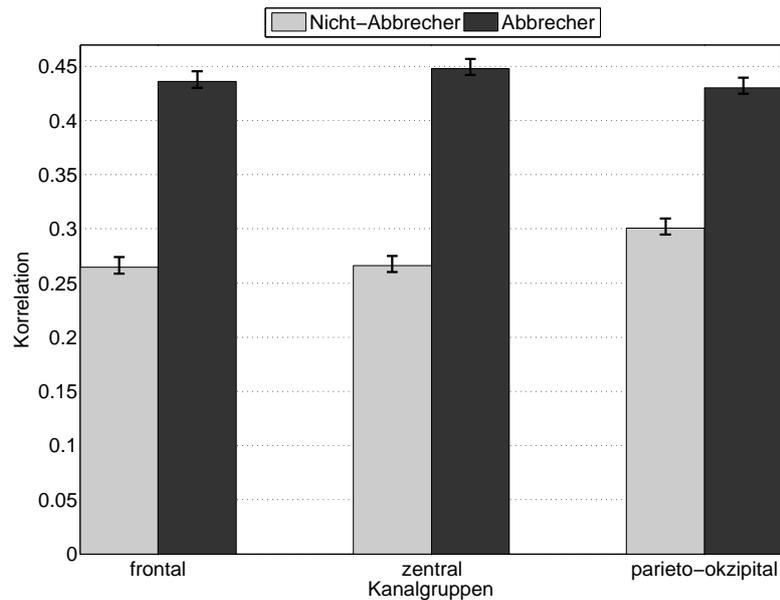


Abbildung 2.17: Mittlere Korrelation zwischen der Rate der Lenkereignisse und der Spindelrate für Abbrecher und Nicht-Abbrecher.

Abbrecher zeigt sich eine moderate Korrelation um 0,44, ohne signifikante Unterschiede zwischen den Kanalgruppen. Die Nicht-Abbrecher hingegen weisen eine schwache Korrelation mit Werten zwischen 0,25 und 0,3 auf, wobei die parieto-okzipitale Spindelrate die stärkere Korrelation mit den Lenkereignissen aufweist. Die ähnlichen Ergebnisse für alle Kanalgruppen decken sich mit vorangegangenen Untersuchungen (z.B. [Abbildung 2.10](#)), wo vergleichbare Auswirkungen der Müdigkeit auf die Parameter der drei Kanalgruppen zu beobachten sind. Individuelle Abweichungen von diesem Muster sind allerdings durchaus möglich, wie [Abbildung 2.18](#) an zwei Beispielen darlegt.

Die Gruppe der Abbrecher weist ein deutlich höheres Müdigkeitsniveau auf, wodurch der Faktor Müdigkeit, neben anderen unbekanntem Störgrößen, die Zeitreihen der Spindelrate und Lenkereignisrate maßgeblich bestimmt und damit die Korrelation der Variablen steigert. Bei Nicht-Abbrechern ist der allgemeine Level der Ermüdung geringer, wodurch auch der Einfluss auf beide Zeitreihen geringer ausfällt. Die Beeinflussung durch weitere unbekanntem Faktoren, welche für beide Zeitreihen verschieden sein können, nimmt hingegen zu und reduziert damit die Korrelation. Darüber hinaus ist anzunehmen, dass Spindelrate und Lenkereignisse teils unterschiedliche Aspekte der Müdigkeit messen. Z.B. muss eine kurze Phase starker Ermüdung nicht immer ein Lenkereignis hervorrufen. Umgekehrt kann eine

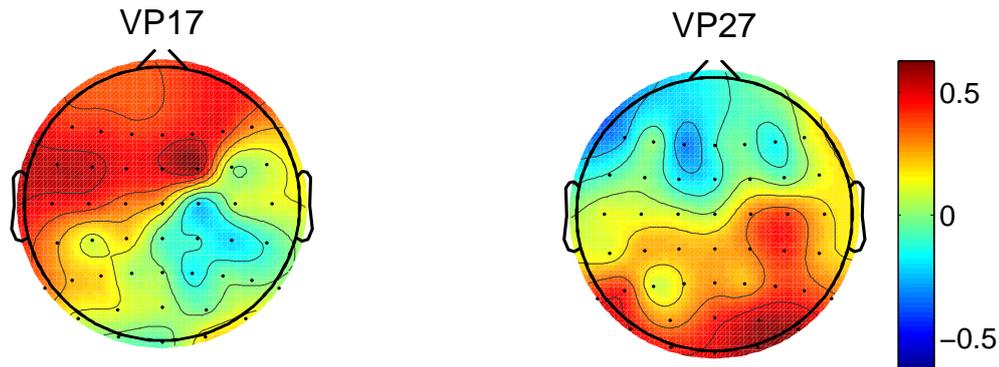


Abbildung 2.18: Beispiel für unterschiedliche Topographien der Korrelation zwischen Spindelrate und Lenkereignisrate. Der Korrelationskoeffizient ist farblich kodiert (s. Farbbalken rechts).

Phase starker Ermüdung durch Überlagerung mit anderen kognitiven Prozessen sowohl ein Lenkmuster erzeugen, aber in atypischen Ausprägungen der Spindelrate resultieren. Diese Tatsachen führen dazu, dass beide Zeitreihen zwar Müdigkeit messen, eine hohe Korrelation zwischen beiden Variablen allerdings nicht zu erwarten ist. Ein weiterer limitierender Faktor ist ein möglicher zeitlicher Versatz im Einfluss der Müdigkeit auf beide Zeitreihen. Es ist anzunehmen, dass sich eine Ermüdung zuerst auf neurophysiologischer Ebene zeigt und erst verzögert in einer Verschlechterung der Fahrperformance resultiert.

Ein komplexes Fahrerassistenzsystem wie „Attention Assist“, welches Müdigkeit anhand des Fahrverhaltens quantifiziert, benötigt eine verlässliche Referenz zur Optimierung der internen Parameter und Validierung des Ansatzes. Darüber hinaus ist zur Exploration weiterer müdigkeitsrelevanter Fahrparameter eine solche Referenz unverzichtbar. Neben Beobachtungen, die im Rahmen dieser Arbeit gemacht wurden (s. Abschnitt 2.3.1), wird eine subjektive Befragung der Probanden auch im Zusammenhang mit der Entwicklung von Fahrerassistenzsystemen als unzureichend eingeschätzt (Friedrichs und Yang, 2010a). Problematisch sind dabei u.a. die zu geringe zeitliche Auflösung, Fehlinterpretationen der Bewertungsskala durch den Probanden und eine widersprüchliche Selbsteinschätzung im Vergleich zum Verhalten und externen Beobachtungen. Deshalb ist eine objektive, zeitlich hoch aufgelöste Müdigkeitsreferenz für die Weiterentwicklung des „Attention Assist“ sehr wichtig. Aktuell verfolgen Wissenschaftler der Daimler AG diesen Ansatz weiter und haben dazu ein Forschungsfahrzeug aufgebaut, um EEG- und eine Vielzahl an Fahrzeugdaten synchron aufzeichnen zu können. Im

Rahmen einer Industriepromotion wird der Zusammenhang zwischen EEG und Fahrverhalten detailliert untersucht.

2.4 Alpha-Spindeln und visuelle Aufmerksamkeit

Der vorangegangene Abschnitt zeigt, dass Alpha-Spindeln eine deutliche Korrelation mit Müdigkeit als einem Langzeitphänomen aufweisen. Dieser Zusammenhang tritt dann verstärkt hervor, wenn Spindelcharakteristika über einen Zeitraum von etwa 3–5 min aggregiert werden. Dem Auftreten einer einzelnen Spindel wird in diesem Kontext wenig Bedeutung beigemessen. Vielmehr sind die gemittelten Eigenschaften vieler Spindeln über einen längeren Zeitraum, z.B. in Form der Spindelrate, wichtig. Es drängt sich nun die Frage auf, ob die einzelne Spindel auch ein Korrelat phasischer kognitiver Prozesse ist oder nur ein Epiphänomen eines Langzeitprozesses darstellt, sodass einzelne Spindeln wenig Gewicht bei kognitiven Prozessen haben. Im folgenden Abschnitt soll dieser Frage genauer nachgegangen werden.

Phasische kognitive Prozesse, die in der Fachliteratur mit Alpha-Aktivität in Verbindung gebracht werden, sind vor allem die kurzzeitige visuelle Informationsverarbeitung. Insbesondere steht der Grad der visuellen Aufmerksamkeit in Zusammenhang mit der Alpha-Aktivität (Ray und Cole, 1985; Foxe et al., 1998; Klimesch et al., 1998; Shaw, 2003). Mehrere Studien zeigen Zusammenhänge zwischen Alpha-Aktivität und räumlicher Aufmerksamkeit (Thut et al., 2006), internalisierter vs. externalisierter Aufmerksamkeit (Cooper et al., 2003) und Modalitätswechsel (visuell vs. akustisch, Foxe et al., 1998) auf. Dies sind Beispiele selektiver Aufmerksamkeitsprozesse, bei denen die Verarbeitung irrelevanter Stimuli (räumlich, modalitätsspezifisch) durch aktive Inhibition von Kortexarealen, welche primär für die Verarbeitung dieser Stimuli verantwortlich sind, unterdrückt wird. Alpha-Aktivität kommt bei der Steuerung dieser Inhibition eine entscheidende Rolle zu (Pfurtscheller und da Silva, 1999; Klimesch et al., 2007). Die Inhibitionshypothese von Klimesch besagt, dass dominante Alpha-Aktivität in einem Kortexareal dessen aktive Inhibition durch top-down regulierte Prozesse darstellt. Irrelevante Informationsverarbeitung wird in diesem Bereich unterdrückt. Da selektive Aufmerksamkeit die Performance in visuell/auditorisch-motorischen Aufgaben entscheidend mitbestimmt, ist dieser Prozess wichtig für das sichere Führen eines Kraftfahrzeugs. Treten simultan Reize unterschiedlicher Modalität auf, ist die Fähigkeit irrelevante Informationen auszublenden wichtig für die Ausübung der Primäraufgabe, in diesem Fall das Führen eines Fahrzeuges. Die Relevanz der einzelnen Alpha-Spindel für diese top-down regulierten, phasischen Aufmerksam-

keitsprozesse soll im Folgenden untersucht werden.

Hintergrund

Mehrere Studien untersuchen die oben beschriebenen Zusammenhänge von Alpha-Aktivität und Aufmerksamkeits- bzw. Inhibitionsprozessen. Die wichtigsten experimentellen Designs und entsprechenden Ergebnisse werden im Folgenden geschildert.

Cooper et al. (2003) zeigen, dass während nach außen gerichteter Aufmerksamkeit die Alpha-Aktivität über parieto-okzipitalen Arealen niedriger ist als bei internalisierter Aufmerksamkeit. Dieser Unterschied besteht unabhängig von der Form der externen Reizdarbietung (visuell, akustisch oder haptisch). Cooper und Kollegen schlussfolgern daraus, dass Alpha-Aktivität eine aktive Inhibition bei internal getriebenen mentalen Operationen repräsentiert.

In einem Experiment von Foxe et al. (1998) wird die Aufmerksamkeit durch einen Hinweisreiz (cue) auf visuelle oder akustische Stimuli gelenkt. Kurz darauf wird gleichzeitig ein akustischer und visueller Stimulus präsentiert und der Proband muss auf den zuvor durch den cue definierten Reiz reagieren. Im Experiment tritt erhöhte parieto-okzipitale Alpha-Aktivität bei Fokussierung auf akustische Reize im Vergleich zur Fokussierung auf visuelle Reize auf. Foxe und Kollegen argumentieren, dass durch Alpha-Aktivität die visuelle Aufmerksamkeit über ein kortiko-thalamisch-kortikales System gesteuert wird und bei Fokussierung auf akustische Reize eine Inhibition der visuellen Verarbeitung auftritt, um irrelevante visuelle Stimuli auszublenden. Ein ähnliches Ablenkungsexperiment, bei dem sowohl Ziel- als auch Ablenkungsstimulus visuell präsentiert werden (Mazaheri et al., 2011), kommt zu dem Ergebnis, dass erhöhte Alpha-Power an Pz auftritt, wenn der ablenkende Stimulus erfolgreich ignoriert wird.

Eine andere Gruppe von Studien (Ergenoglu et al., 2004; Linkenkaer-Hansen et al., 2004; van Dijk et al., 2008; Mathewson et al., 2009) befasst sich mit der spontan fluktuierenden Performance in visuellen Detektionsaufgaben. Hier werden visuelle Stimuli nahe der Wahrnehmungsschwelle verwendet. Für realitätsnahe Experimente ist interessant, dass bei diesen Studien die Unterschiede in der Detektionsperformance nur durch spontane Schwankung der Aufmerksamkeit hervorgerufen werden. Im Vergleich zu den vorher beschriebenen Studien sind hier die experimentellen Bedingungen weniger kontrolliert, da die Ursache für einen unerkannten Reiz auf Grund spontaner Aufmerksamkeitschwankungen nicht genau

festgestellt werden kann. Alle erwähnten Studien kommen zu dem Ergebnis, dass bei Verringerung der Detektionsperformance die Prästimulus-Leistung im Alpha-Band an parieto-okzipitalen Elektroden höher ist. Dieser Effekt wird ebenfalls mit der Inhibition visueller Verarbeitung durch spontane Aufmerksamkeitsschwankungen erklärt. Die Autoren argumentieren, dass erhöhte Alpha-Aktivität über einem Kortexbereich die Informationsverarbeitung in diesem Areal hemmt.

Da mit dem Auftreten einer Alpha-Spindel eine erhöhte Alpha-Aktivität einhergeht, stellt sich nun die Frage ob während einer Spindel eine verringerte visuelle Verarbeitungsleistung vorliegt. Analog zu den obigen Studien wird eine verstärkte Inhibition visueller Areale während dem Auftreten einer Spindel vermutet. Gründe für die Inhibition können (i) das bewusste Abwenden der Aufmerksamkeit von visuellen Stimuli, (ii) reduzierte visuelle Verarbeitung auf Grund verringerter Vigilanz oder (iii) spontane Fluktuationen in der Aufmerksamkeit sein. Innerhalb meiner Forschungsgruppe bei der Daimler AG gibt es zu Punkt (i) eine Arbeit, bei der die Analysen zeigen, dass Spindeln den Wechsel von visueller zu akustischer Aufmerksamkeit deutlich nachbilden (Sonnleitner et al., 2012). Bei der Konzentration auf akustische Reize steigt die Anzahl der Spindeln deutlich an, was als eine Fokussierung auf internalisierte Verarbeitung akustischer Stimuli bei gleichzeitiger reduzierter visueller Informationsverarbeitung interpretiert wird. Der Zusammenhang zwischen Spindeln und Vigilanz ist in Abschnitt 2.3.3 dieser Arbeit ausführlich beschrieben.

Für die Verkehrssicherheit sind spontane Fluktuationen von Aufmerksamkeit (iii) relevant, insbesondere bei lang andauernden, monotonen Aufgaben, wie z.B. Autofahrten. Hier kann durch Abdriften der Aufmerksamkeit vom Fahrgeschehen eine erhebliche Reduktion der Reaktionszeit für z.B. Bremsmanöver entstehen, was zu gefährlichen Auffahrunfällen führen kann.

Im nachfolgend beschriebenen Experiment wird untersucht, ob die einzelne Alpha-Spindel an parieto-okzipitalen Elektroden mit kurzzeitigen Aufmerksamkeitsschwankungen zusammenhängt. Wie in den vorherigen Studien ist auch hier ein realistisches experimentelles Setup gefordert, um Ergebnisse des Versuchs auf das Autofahren zu übertragen. Da die erwarteten Effekte gering sind, wird zunächst ein Versuch im Fahr Simulator aufgesetzt, um den Einfluss unbekannter Störungen und Reize gering zu halten. Im Anschluss wird das gleiche experimentelle Paradigma auch bei einer Realfahrt untersucht, um festzustellen ob ähnliche Effekte auch in diesem Umfeld, mit einer Vielzahl an externen Reizen und unbe-

kannten Störeinflüssen, noch zu beobachten sind.

Um Aufmerksamkeitsschwankungen zu erfassen bieten sich Performancemaße mit unterschiedlichen Aufgabenmodalitäten an. Die Fahraufgabe selbst ist relativ unempfindlich gegenüber kurzzeitigen Aufmerksamkeitsschwankungen, da insbesondere auf der Autobahn die Umgebung stark vorhersehbar ist. Eine experimentelle Manipulation der Fahraufgabe ist im realen Straßenverkehr ebenfalls nicht möglich. Deshalb wird mit Hilfe einer Zweitaufgabe, die gleichzeitig mit dem Fahrversuch abläuft und das Fahren als Primäraufgabe nicht beeinträchtigen darf, die Kurzeitaufmerksamkeit beobachtet. Es wird ein akustischer Reiz verwendet, auf den der Proband möglichst schnell reagieren soll. Schwankungen in der Reaktionszeit und Detektionsrate repräsentieren in diesem Zusammenhang Änderungen der Aufmerksamkeit auf akustische Reize. Auf diese Weise lässt sich indirekt auch die visuelle Aufmerksamkeit messen, die mit Alpha-Spindeln in Verbindung steht, wie obige Studien zeigen. Hier liegt das Konzept der geteilten Aufmerksamkeit zu Grunde (Posner und Rafal, 1987), welches bestimmte Modalitäten oder Raumbereiche favorisiert und die Leistungsfähigkeit hier partiell verstärkt (Crick, 1984). Nach dem Ressourcenmodell von Wickens (1984) führt dies zu Performanceeinbußen in nicht-aufgabenrelevanten Modalitäten, da auf Grund begrenzter Ressourcen irrelevante Objekte weniger effektiv verarbeitet werden. Demnach kann eine geringe Reaktionszeit auf einen akustischen Reiz als Indikator für hohe akustische Aufmerksamkeit und gleichzeitig verringerte visuelle Aufmerksamkeit interpretiert werden.

Hypothesen

- Tritt ein akustischer Reiz gleichzeitig mit einer parieto-okzipitalen Alpha-Spindel auf, so verringert sich die Reaktionszeit auf diesen Reiz und die Detektionsrate erhöht sich, im Vergleich zu akustischen Reizen, die nicht mit einer Alpha-Spindel zusammenfallen. Grund hierfür ist eine geringere visuelle Aufmerksamkeit während einer Alpha-Spindel, wodurch mehr Ressourcen für die Verarbeitung akustischer Reize zur Verfügung stehen.
- Alpha-Spindeln haben einen größeren Einfluss auf die Reaktionszeit bei schwieriger zu detektierenden akustischen Reizen, da hier mehr Ressourcen und eine höhere Aufmerksamkeit erforderlich sind.
- Bei steigenden kognitiven Anforderungen der Primäraufgabe verstärkt sich

der Effekt der Alpha-Spindel auf die Reaktionszeit, da insgesamt weniger Ressourcen zur Bearbeitung der Zweitaufgabe zur Verfügung stehen.

2.4.1 Experimentbeschreibung

Primäre Aufgabe ist die Bedienung eines einfachen Fahrsimulators (LCT, Lane Change Task: [Mattes \(2003\)](#)) mittels eines Lenkrades mit Pedalerie (Logitech Formula Force GP), wobei der optische Fluss, also die Menge der zu verarbeitenden Informationen, sowie die Relevanz und Komplexität der Fahraufgabe in drei Stufen variiert wird. In Bedingung 1 (*Fixation*) wird ausschließlich ein Fixationskreuz in der Mitte des Bildschirms präsentiert. In Bedingung 2 (*passiv*) läuft ein Video des Fahrsimulators ab, dem der Proband zuschaut. In Bedingung 3 (*aktiv*) muss der Proband den Simulator schließlich selbst bedienen. Von Bedingung 1 zu 2 erhöht sich der optische Fluss und damit die Menge der zu verarbeitenden Informationen. Der Wechsel von Bedingung 2 zu 3 steigert zusätzlich die Relevanz der visuellen Information durch aktive Involvierung in die dargebotene Fahrsituation. Damit verbunden ist auch eine höhere kognitive Beanspruchung. Die Abstufungen im Faktor *Bedingung* ermöglichen die Untersuchung des Einflusses der Alpha-Spindel auf die visuelle Verarbeitung bei verschiedenen komplexen Primäraufgaben bzw. zunehmender visueller Informationsmenge. Bedingung 1 und 2 sind jeweils 10 min und Bedingung 3 20 min lang. Das Experiment ist in zwei Blöcke unterteilt, mit einer kurzen Pause zwischen den Blöcken. Ein Block besteht aus allen drei Bedingungen, wobei die Reihenfolge der Bedingungen innerhalb jedes Blocks randomisiert ist, um eine Konfundierung von time-on-task Effekten mit den Bedingungen zu vermeiden. Der gesamte Versuch dauert ca. 1,5 Stunden.

Für das Experiment im realen Straßenverkehr darf die Sekundäraufgabe aus Sicherheitsgründen nicht mit der eigentlichen Fahraufgabe interferieren. Deshalb wird ein modifiziertes auditorisches Oddball-Paradigma verwendet, bei dem nicht nur, wie sonst üblich, auf den seltenen Zielreiz reagiert werden muss, sondern auch auf den häufigen Ablenkungsreiz. Die Parameter des Oddball-Paradigma sind wie folgt festgelegt:

- häufiger Ton: Wahrscheinlichkeit: 80%, Frequenz: 400 Hz
- seltener Ton: Wahrscheinlichkeit: 20%, Frequenz: 500 Hz
- Tonlänge: je 70 ms
- Interstimulus-Interval: 4–6 s

Reagiert wird über Taster, die an den Daumen beider Hände befestigt sind, so dass die Bedienung eines Lenkrades weiterhin problemlos möglich ist (s. Abbildung 2.19). Mit welcher Hand auf den seltenen bzw. häufigen Reiz reagiert werden muss, wird vor dem Experiment zufällig für jeden Probanden festgelegt und nach dem 1. Block wird die Zuordnung getauscht, um einen Bias auf Grund der Händigkeit zu vermeiden.



Abbildung 2.19: Aufbau des Laborversuchs.

Die anschließende Fahrt im Realverkehr entspricht dem Experiment II aus Abschnitt 2.3.2. Eine detaillierte Beschreibung ist in diesem sowie in Abschnitt 2.3.1 zu finden. Die auditorische Nebenaufgabe ist hier äquivalent zum Laborversuch, wobei die Ausübung der Fahraufgabe immer Priorität hat. Stimuli während Wendemanövern und Spurwechseln sind vor der Analyse entfernt worden, da hier durch die Bedienung des Lenkrades und der Blinkerhebel eine verlangsamte Reaktion zu erwarten ist.

Von den Daten 30 rekrutierter Probanden werden zwei Datensätze des Laborversuchs auf Grund schlechter Datenqualität von der weiteren Auswertung ausgeschlossen. Für den Fahrversuch stehen 24 valide Datensätze zur Verfügung, da weitere vier mangels unzureichender Datenqualität nicht verwendet werden können.

Der Laborversuch beginnt um 10 Uhr und dauert ca. 1,5 Stunden. Die Probanden werden angewiesen in der Nacht zuvor ausreichend zu schlafen, um ausgeruht am Versuch teilzunehmen. Durchschnittliche KSS-Werte bei Versuchsbeginn liegen bei $3,2 \pm 1,2$, was auf einen wachen und ausgeruhten Zustand der Probanden

hindeutet. An eine einstündige Mittagspause schliesst sich der Fahrversuch an, der bis ca. 17 Uhr andauert. Es kommt das gleiche EEG-System mit 64 Elektroden wie in Abschnitt 2.3.2 zum Einsatz. Die EEG-Haube wird zwischen den Versuchen nicht abgenommen.

Alpha-Spindeln werden nach der Methode aus Abschnitt 2.1.1 für parieto-okzipitale Kanäle bestimmt (s. Tabelle 2.2). Reaktionszeiten kürzer als 200 ms werden aus der Analyse ausgeschlossen und Reaktionszeiten länger als 2 s oder keine Reaktion werden als Verpasser gewertet. Falsche Alarme sind Reaktionen, bei denen der Proband mit der falschen Hand reagiert. Die Koinzidenz eines Stimulus und einer Spindel ist definiert als das Präsentieren eines Stimulus während gleichzeitig mindestens eine Spindel über dem parieto-okzipitalen Kortex auftritt.

2.4.2 statistische Methoden

Zur statistischen Analyse der beiden Versuche wird anstatt der üblichen Varianzanalyse mit Messwiederholung ein *lineares gemischtes Modell* (linear mixed model, LMM) verwendet. Das Modell, sowie Vorteile gegenüber einer Varianzanalyse, sind im folgenden Abschnitt näher beschrieben. In Abschnitt 2.4.2.2 wird weiterhin das *generalisierte lineare gemischte Modell* geschildert, welches eine Verallgemeinerung des LMMs ist und sich besonders für die Analyse der Detektionsraten eignet.

2.4.2.1 Das lineare gemischte Modell (LMM)

Allgemeines lineares Modell

Im allgemeinen linearen Modell (ALM) werden n unabhängige Messungen einer metrischen Zielvariable y_i und k Kovariaten $\mathbf{x}_i = (1, x_{i1}, \dots, x_{ik})'$ erhoben ($k < n$); für diese nimmt man einen linearen Zusammenhang an (Fahrmeir et al., 2007):

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + \varepsilon_i, \quad i = 1, \dots, n. \quad (2.7)$$

In Matrixschreibweise ergibt sich

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad (2.8)$$

mit $\mathbf{y} = (y_1, \dots, y_n)'$, $\boldsymbol{\beta} = (\beta_0, \dots, \beta_k)'$, $\boldsymbol{\varepsilon} = (\varepsilon_1, \dots, \varepsilon_n)'$ und der Designmatrix

$$\mathbf{X} = \begin{pmatrix} 1 & x_{11} & \dots & x_{1k} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & \dots & x_{nk} \end{pmatrix}.$$

Weiter wird angenommen, dass die Fehler $\boldsymbol{\varepsilon}$ des Modells unabhängig und identisch multivariat normalverteilt sind: $\boldsymbol{\varepsilon} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I}_n)$. \mathbf{y} ist damit ebenfalls normalverteilt mit $\mathbf{y} \sim \mathcal{N}(\mathbf{X}\boldsymbol{\beta}, \sigma^2 \mathbf{I}_n)$. Die Parameter $\boldsymbol{\beta}$ des Modells 2.8 lassen sich durch die Methode der kleinsten Quadrate (*least squares*) schätzen:

$$LS(\boldsymbol{\beta}) = \sum_{i=1}^n (y_i - \mathbf{x}_i' \boldsymbol{\beta})^2. \quad (2.9)$$

Minimierung von 2.9 bezüglich $\boldsymbol{\beta}$ führt unter der Annahme, dass \mathbf{X} vollen Rang hat zu folgender Lösung:

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}.$$

Der LS-Schätzer $\hat{\boldsymbol{\beta}}$ ist der beste, lineare, erwartungstreue Schätzer für $\boldsymbol{\beta}$ (BLUE).

Hypothesentests für die Parameter β_i sind beispielsweise auf Basis des Likelihood-Quotienten Tests oder Wald-Tests möglich.

Mit Hilfe des allgemeinen linearen Modells lässt sich eine Vielzahl bekannter statistischer Verfahren abbilden. Hierzu zählen u.a. der t-Test, ein- und mehrfaktorielle Varianzanalysen sowie multiple Korrelations- und Regressionsrechnungen (Bortz, 2005). Die unterschiedlichen Methoden lassen sich über entsprechende Formen der Designmatrix \mathbf{X} realisieren. Die Kovariaten \mathbf{x}_i können sowohl kontinuierliche als auch nominalskalierte Variablen sein. Im 2. Fall werden die Kovariaten auch als Faktoren bezeichnet und über spezielle Kodierungen in Indikatorvariablen umgewandelt. In der Regel wird ein k-fach gestufter Faktor durch k-1 Indikatorvariablen verschlüsselt. Übliche Kodierungsformen sind die Dummy-, Effekt- und Kontrastkodierung. Durch die Kodierung wird die Bedeutung der Modellparameter $\boldsymbol{\beta}$ festgelegt.

Als Anwendungsbeispiel für das ALM wird die Umsetzung einer einfaktoriellen Varianzanalyse in diesem Modell beschrieben. Eine Kovariate, welche die k Stufen des experimentellen Faktors beschreibt, wird in k-1 Indikatorvariablen mittels einer Effektkodierung umgewandelt. Für das Beispiel soll ein Faktor mit 3 Stufen und $n = 9$ angenommen werden. Die erste Indikatorvariable erhält dabei eine

1 für alle Werte aus Stufe 1 und eine Null für alle Werte aus Stufe 2. Stufe 3 wird mit einer -1 kodiert. Für die zweite Indikatorvariable werden alle Werte aus Stufe 1 mit Null, aus Stufe 2 mit 1 und Stufe 3 wieder mit -1 kodiert. Für jede Indikatorvariable muss gelten $\sum_{i=1}^n x_{ij} = 0$, $j = 1, 2$. Um die Konstante β_0 zu schätzen, muss zusätzlich ein Spaltenvektor mit Einsen eingefügt werden. Die Designmatrix \mathbf{X} ergibt sich damit zu

$$\mathbf{X} = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 0 & 0 & 0 & -1 & -1 & -1 \\ 0 & 0 & 0 & 1 & 1 & 1 & -1 & -1 & -1 \end{pmatrix}'.$$

Bei einer Effektkodierung entspricht β_0 dem Gesamtmittelwert μ von \mathbf{y} und jedes β_i -Gewicht der Differenz des Mittelwertes der Stufe i vom Gesamtmittelwert ($\mu_i - \mu$). Die zu prüfende Nullhypothese der Varianzanalyse lautet: $H_0 : \mu_1 = \mu_2 = \dots = \mu_k$, wobei μ_i der Mittelwert in Stufe i ist. Für das ALM kann ebenfalls eine globale Nullhypothese $\tilde{H}_0 : \beta_1 = \beta_2 = \dots = \beta_{k-1} = 0$ formuliert werden (Bortz, 2005). Da $\beta_i = \mu_i - \mu$, bedeutet \tilde{H}_0 , dass zwischen den Mittelwerten μ_i aller Stufen kein Unterschied besteht. Damit sind die Hypothesen H_0 und \tilde{H}_0 äquivalent. Allerdings kann mit der Überprüfung der separaten Nullhypothese $H_0 : \beta_i = 0$ für jeden Parameter eine deutlich genauere Inferenz erzielt werden, was bei einer Varianzanalyse nur mit post-hoc Tests möglich ist. Wird im obigen Beispiel anstatt der Effektkodierung die Dummykodierung verwendet, so gilt für die Designmatrix

$$\mathbf{X} = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 0 \end{pmatrix}'.$$

Der Koeffizient β_i gibt nun nicht mehr die Abweichung der mittleren Ausprägung in der i -ten Stufe vom Gesamtmittelwert, sondern vom Mittelwert der Referenzkategorie an. Die Referenzkategorie entspricht jener Faktorstufe, die bei der Dummykodierung vollständig mit Nullen belegt wird. Im obigen Beispiel ist dies Stufe 3. Auf Grund der direkten Gegenüberstellung der Mittelwerte zwischen den Faktorstufen ist die Dummykodierung für die nachfolgenden Analysen besonders geeignet.

Lineares gemischtes Modell

Lineare gemischte Modelle (LMM) erweitern das ALM mit den festen Effekten $\mathbf{X}\boldsymbol{\beta}$ um sog. zufällige Effekte (random effects). Diese Modelle eignen sich besonders für die Analyse gruppierter Daten, bei denen im Messvektor \mathbf{y} Untergruppen vorhanden sind, sodass die Messungen y_i innerhalb einer Gruppe nicht mehr unabhängig sind (Fahrmeir et al., 2007). Weiterhin können die Untergruppen unterschiedliche Modellparameter $\boldsymbol{\beta}$ besitzen. Dies tritt z.B. auf, wenn an verschiedenen Probanden über einen gewissen Zeitraum wiederholt gemessen wird. Jeder Proband bildet dann eine solche Untergruppe. Ein weiteres Beispiel für solche natürlichen Cluster sind hierarchisch gestufte Daten wie z.B. Schulklassen innerhalb einer Schule. Die Einführung zufälliger Effekte ermöglicht es probanden- und clusterspezifische Effekte zu modellieren. Während im ALM gleiche Modellkoeffizienten $\boldsymbol{\beta}$ für alle Probanden angenommen werden, sind mit Hilfe zufälliger Effekte Abweichungen von diesen Populationsparametern für jeden Probanden möglich. Die Regressionsgeraden können sich folglich zwischen den Clustern sowohl im Niveau als auch in der Steigung unterscheiden.

LMMs bieten eine Reihe von Vorteilen gegenüber der klassischen Vorgehensweise bei der Analyse gruppierter oder messwiederholter Daten. Zu den klassischen Ansätzen zählen die messwiederholte ANOVA (repeated measures, RM-ANOVA) sowie die MANOVA. Als Vorteile eines LMMs sind im wesentlichen folgende Punkte zu nennen:

- Fehlende Daten für einzelne Probanden stellen kein Problem dar. Im Gegensatz zu einer RM-ANOVA, bei der bereits ein einzelner fehlender Wert im messwiederholten Faktor zum Ausschluss des gesamten Probanden führt, werden beim LMM alle vorhandenen Daten verwendet.
- Diskrete Faktoren, wie z.B. Geschlecht, und kontinuierliche Variablen, wie z.B. Zeit, können in ein Modell integriert werden.
- Die Sphäritätsannahme, eine Voraussetzung für die RM-ANOVA, muss nicht erfüllt sein. Die Annahme impliziert identische Varianz in allen Stufen eines Faktors und gleiche Korrelationskoeffizienten zwischen den Faktorstufen (Bortz, 2005). Beide Voraussetzungen sind in der Praxis jedoch häufig verletzt. Da die Struktur der Fehlerkovarianzmatrix im LMM sehr flexibel modelliert werden kann, ist es möglich, beliebige Korrelationsstrukturen der Daten in das Modell einzubinden.

- Die Regressionskoeffizienten eines LMMs können leichter interpretiert werden als die Quadratsummen einer ANOVA.

In der Praxis ist die Anzahl der Beobachtungen pro Proband häufig verschieden. Im Falle des hier beschriebenen Experimentes ist z.B. die Anzahl der Reaktionszeiten (RT) auf Stimuli während bzw. außerhalb einer Spindel nicht gleich groß. Für die RM-ANOVA ist jedoch ein balanciertes Experimentdesign notwendig. Um eine identische Anzahl Beobachtungen pro Proband zu erhalten, werden in der Praxis die Beobachtungen pro Proband und Faktorstufe gemittelt - offensichtlich geht dabei Information verloren. Zum einen geht die Varianz der ungemittelten Daten nicht mehr in die Analyse ein. Zum anderen spielt die Genauigkeit des Mittelwertes in der darauf folgenden RM-ANOVA keine Rolle. Diese ist vom Umfang der zu Grunde liegenden Stichprobe abhängig, welche zwischen den Probanden beträchtlich variieren kann. Im Gegensatz dazu kann im LMM eine unterschiedliche Stichprobengröße für jeden Probanden verwendet werden, weshalb es keiner Mittelung der Daten bedarf. Deshalb wird im LMM die gesamte Varianz der Daten berücksichtigt, was zu aussagekräftigeren Ergebnissen führt.

Probandenspezifische Regressionskoeffizienten können auch durch die separate Schätzung eines ALMs pro Proband

$$\mathbf{y}_i = \mathbf{Z}_i \boldsymbol{\beta}_i + \boldsymbol{\varepsilon}_i \quad \forall i = 1, \dots, n \quad (2.10)$$

bestimmt werden (Verbeke und Molenberghs, 2001). In Gleichung 2.10 bezeichnet $\mathbf{y}_i = (y_{i1}, y_{i2}, \dots, y_{in_i})'$ den Messvektor für Individuum i mit n_i wiederholten Messungen. \mathbf{Z}_i ist eine $(n_i \times q)$ Matrix mit q bekannten Kovariaten. $\boldsymbol{\beta}_i$ ist ein q -dimensionaler Spaltenvektor probandenspezifischer Koeffizienten und $\boldsymbol{\varepsilon}_i$ ein n_i -dimensionaler Fehlervektor. Mit diesem Modell wäre der individuellen Ausprägung der Modellparameter $\boldsymbol{\beta}_i$ Rechnung getragen, allerdings fehlt hier die eigentlich interessierende Schätzung des Populationsparameters $\boldsymbol{\beta}$. Ein weiterer Nachteil dieses Vorgehens ist die mit der Anzahl der Individuen linear steigende Anzahl an Modellparametern. Es kann nun ein weiteres Regressionsmodell verwendet werden, um auf die Populationsparameter zu schließen:

$$\boldsymbol{\beta}_i = \mathbf{K}_i \boldsymbol{\beta} + \mathbf{b}_i \quad (2.11)$$

\mathbf{K}_i ist eine $(q \times p)$ Matrix bekannter Kovariaten und $\boldsymbol{\beta}$ ein p -dimensionaler Populationsparameter. Die Residuen $\mathbf{b}_i = (b_{i1}, b_{i2}, \dots, b_{iq})'$ sind die zufälligen Abwei-

chungen der individuellen Parameter vom Populationsparameter. Ersetzt man β_i in 2.10 mit 2.11, erhält man für das i -te Individuum ($i = 1, \dots, n$):

$$\mathbf{y}_i = \mathbf{X}_i \boldsymbol{\beta} + \mathbf{Z}_i \mathbf{b}_i + \boldsymbol{\varepsilon}_i \quad (2.12)$$

mit $\mathbf{X}_i = \mathbf{Z}_i \mathbf{K}_i$ ($\mathbf{X}_i \in \mathbb{R}^{n_i \times p}$). Das Modell 2.12 besteht aus sog. festen Effekten $\boldsymbol{\beta}$ und zufälligen Effekten \mathbf{b}_i und wird auf Grund der Mischung der beiden Effekttypen lineares gemischtes Modell genannt. Mit $\boldsymbol{\beta}$ lassen sich Aussagen über die gesamte Population treffen, wohingegen die zufälligen Effekte \mathbf{b}_i individuen-spezifische Abweichungen von $\boldsymbol{\beta}$ modellieren. \mathbf{Z}_i enthält die Kovariaten der zufälligen Effekte und kann aus bereits in \mathbf{X}_i enthaltenen Variablen bestehen, aber auch neue Kovariaten enthalten. Es gelten folgende Verteilungsannahmen

$$\mathbf{b}_i \sim \mathcal{N}(\mathbf{0}, \mathbf{D}) \text{ und } \boldsymbol{\varepsilon}_i \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\Sigma}_i).$$

Weiter wird angenommen, dass $\mathbf{b}_1, \dots, \mathbf{b}_n$ und $\boldsymbol{\varepsilon}_1, \dots, \boldsymbol{\varepsilon}_n$ unabhängig sind. \mathbf{D} ist eine $(q \times q)$ Kovarianzmatrix und ermöglicht die Modellierung komplexer Abhängigkeitsstrukturen zwischen den zufälligen Effekten. In der Praxis wird häufig ein einfaches Modell mit Diagonalmatrix \mathbf{D} verwendet (*Varianzkomponenten*). $\boldsymbol{\Sigma}_i$ ist eine $(n_i \times n_i)$ dimensionale positiv definite Fehlerkovarianzmatrix. Komplexe Strukturen für $\boldsymbol{\Sigma}_i$ erlauben die Modellierung heteroskedastischer Fehler, wobei auch hier häufig eine einfache Struktur ($\boldsymbol{\Sigma}_i = \sigma^2 \mathbf{I}_{n_i}$) angenommen wird. \mathbf{I}_{n_i} bezeichnet eine $(n_i \times n_i)$ Einheitsmatrix. Hier wird angenommen, dass die n_i Beobachtungen von Subjekt i bei gegebenem \mathbf{b}_i und $\boldsymbol{\beta}$ unabhängig sind und gleiche Varianz σ^2 haben.

Das marginale Modell (Randverteilung von \mathbf{y}_i) kann aufgestellt werden, indem man ein lineares Regressionsmodell (mit heteroskedastischen Fehlern) aufstellt (Fahrmeir et al., 2007):

$$\mathbf{y}_i = \mathbf{X}_i \boldsymbol{\beta} + \boldsymbol{\varepsilon}_i^*, \quad \boldsymbol{\varepsilon}_i^* = \mathbf{Z}_i \mathbf{b}_i + \boldsymbol{\varepsilon}_i$$

\mathbf{y}_i ist dann normalverteilt mit

$$\mathbf{y}_i \sim \mathcal{N}(\mathbf{X}_i \boldsymbol{\beta}, \mathbf{V})$$

mit Kovarianzmatrix $\mathbf{V}_i = \mathbf{Z}_i \mathbf{D} \mathbf{Z}_i' + \boldsymbol{\Sigma}_i$. Der Erwartungswert $\mathbf{X}_i \boldsymbol{\beta}$ enthält nur noch Informationen über die Gesamtpopulation und sagt nichts mehr über einzelne

Individuen aus. Das marginale Modell ist Ausgangspunkt für die Aufstellung der Likelihood-Funktion zur Parameterschätzung.

Die Schätzung der Modellparameter wird üblicherweise in zwei Schritten durchgeführt. Für die Schätzung der Kovarianzmatrix \mathbf{V}_i wird die sog. restringierte Maximum-Likelihood-Funktion (REML) verwendet (Pinheiro und Bates, 2000), da diese gegenüber der Maximum-Likelihood Schätzung eine geringere Verzerrung aufweist.

Es seien alle unbekannt Parameter der Kovarianzmatrix \mathbf{V}_i im Vektor $\boldsymbol{\alpha}$ zusammengefasst. Ausgangspunkt für die Schätzung ist die Likelihood $L(\boldsymbol{\beta}, \boldsymbol{\alpha})$ des marginalen Modells ???. Durch Integration über $\boldsymbol{\beta}$

$$L_R(\boldsymbol{\alpha}) = \int L(\boldsymbol{\beta}, \boldsymbol{\alpha}) d\boldsymbol{\beta}$$

erhält man die marginale Likelihood $L_R(\boldsymbol{\alpha})$ (auch restringierte Likelihood), welche nicht mehr von $\boldsymbol{\beta}$ abhängt und damit zur Bestimmung von $\boldsymbol{\alpha}$ (restringierter ML-Schätzer, REML) verwendet werden kann. Die log-Likelihood ergibt sich zu (Fahrmeir et al., 2007):

$$l_R(\boldsymbol{\alpha}) = -\frac{1}{2} \sum_{i=1}^n \left\{ \log |\mathbf{V}_i(\boldsymbol{\alpha})| + \log \left| \mathbf{X}_i' \mathbf{V}_i(\boldsymbol{\alpha})^{-1} \mathbf{X}_i \right| + (\mathbf{y}_i - \mathbf{X}_i' \hat{\boldsymbol{\beta}})' \mathbf{V}_i(\boldsymbol{\alpha})^{-1} (\mathbf{y}_i - \mathbf{X}_i' \hat{\boldsymbol{\beta}}) \right\} \quad (2.13)$$

Anschließend werden die geschätzten Kovarianzparameter $\hat{\boldsymbol{\alpha}}$ verwendet, um $\boldsymbol{\beta}$ über den Maximum-Likelihood Schätzer der linearen Regression (gewichteter KQ-Schätzer)

$$\hat{\boldsymbol{\beta}}(\hat{\boldsymbol{\alpha}}) = \left(\sum_{i=1}^n \mathbf{X}_i' \hat{\mathbf{V}}_i^{-1} \mathbf{X}_i \right)^{-1} \sum_{i=1}^n \mathbf{X}_i' \hat{\mathbf{V}}_i^{-1} \mathbf{y}_i \quad (2.14)$$

zu bestimmen. Die Berechnung des REML-Schätzers der Kovarianzmatrix kann iterativ über Expectation-Maximization oder das Newton-Raphson Verfahren gelöst werden. Ein hybrider Ansatz aus beiden Methoden ist ebenfalls möglich (Pinheiro und Bates, 2000).

Die Schätzung von \mathbf{b}_i erfolgt über einen bayesschen Ansatz, bei dem die gesuchten Parameter durch eine a-posteriori Dichte bedingt auf die Messwerte \mathbf{y}_i definiert sind. Unter der Annahme $\mathbf{b}_i \sim \mathcal{N}(\mathbf{0}, \mathbf{D})$ für die a-priori Verteilung folgt die Dichtefunktion der a-posteriori Verteilung einer multivariaten Normalverteilung.

Als Schätzer für \mathbf{b}_i wird üblicherweise der Mittelwert dieser Verteilung verwendet

$$\hat{\mathbf{b}}_i = E[\mathbf{b}_i | \mathbf{Y}_i = \mathbf{y}_i] = \mathbf{D}\mathbf{Z}'_i\mathbf{V}_i^{-1}(\mathbf{y}_i - \mathbf{X}_i\boldsymbol{\beta}) \quad (2.15)$$

(Verbeke und Molenberghs, 2001). Werden in 2.15 die Parameter der festen Effekte und die Kovarianzmatrix durch ihre ML bzw. REML-Schätzer ersetzt, so wird $\hat{\mathbf{b}}_i$ auch als *empirical Bayes* (EB) Schätzer bezeichnet.

Von primärem Interesse sind in der Regel Hypothesentests für die festen Effekte (z.B. $H_0 : \beta_i = 0$). Die geschätzten Modellparameter $\hat{\boldsymbol{\beta}}$ sind approximativ normalverteilt, weshalb approximative Tests (Wald- oder t-Test) zur Anwendung kommen (Fahrmeir et al., 2007). Generell gilt, dass beide Tests bei kleinen Stichproben stark verzerrte p-Werte liefern können. Baayen et al. (2008) schlagen deshalb Markov Chain Monte Carlo Sampling (MCMC) zur Bestimmung der p-Werte vor. Alternativ ist auch ein Likelihood-Quotienten-Test möglich (LQ-Test). Hier werden die Likelihoods für zwei Modelle berechnet, bei denen der zu testende Parameter in einem allgemeineren Modell enthalten ist und in einem reduzierten Modell nicht. Trägt der zu testende Parameter signifikant zur Verbesserung des Modells bei, so ist die Likelihood L_1 des allgemeineren Modells größer als die Likelihood L_2 des einfacheren Modells. Der Quotient aus den logarithmierten Likelihoods

$$2 \log\left(\frac{L_1}{L_2}\right) = 2(\log(L_1) - \log(L_2))$$

ist demnach positiv und folgt asymptotisch einer Chi-Quadrat-Verteilung mit Freiheitsgraden gleich der Differenz der Dimensionen der beiden Modelle (Pinheiro und Bates, 2000). Kann H_0 verworfen werden, trägt der zusätzliche Parameter signifikant zur Erhöhung der Likelihood bei und ist somit ein relevanter Effekt. Der Likelihood-Quotienten-Test ist vor allem zum Testen der zufälligen Effekte auf Signifikanz geeignet.

Es ist allerdings zu bemerken, dass die vielseitigen Möglichkeiten, das LMM zu parametrisieren auch zu massivem Overfitting führen kann, insbesondere bei kleinen Stichproben. Da die Likelihood nur iterativ maximiert werden kann, können bei komplexen Modellen auch Konvergenzprobleme auftreten. Demnach ist hier ein erheblich höherer Aufwand notwendig, um ein passendes Modell zu bestimmen und zu validieren als bei herkömmlichen Methoden, wie z.B. einer Varianzanalyse. Das beste Vorgehen ist, wie immer, durch a-priori Wissen bereits eine geeignete Modellstruktur mit sinnvollen Interaktionstermen und Kovarianzstrukturen zu

wählen. Ist dies nicht möglich, kann auf Basis des LQ-Tests aus einer Menge verschieden komplexer Modeller jenes mit der besten Anpassung und den wenigsten Parametern identifiziert werden.

Sämtliche Analysen für gemischte Modelle werden in der Programmiersprache **R** (R Development Core Team, 2011) mit Hilfe des Pakets **lme4** (Linear mixed-effects models using S4 classes, (Bates und Sarkar, 2007)) durchgeführt.

2.4.2.2 Das generalisierte lineare gemischte Modell (GLMM)

Generalisierte lineare Modelle (GLM)

Lineare Regressionsmodelle gehen von einer stetigen Zielvariable aus, die normalverteilt ist. In vielen Anwendungsbeispielen ist die Zielvariable allerdings nicht stetig, sondern binär bzw. kategorial oder eine Zählvariable. Beispiele hierfür sind das Vorhandensein/Nicht-Vorhandensein einer Krankheit, ein Fragebogen-Item mit einer 5-stufigen Bewertungsskala oder die Anzahl von Schadensfällen in einem bestimmten Zeitraum (Fahrmeir et al., 2007). Auch kann es sinnvoll sein, stetige Zielvariablen mit stark von einer Normalverteilung abweichenden Eigenschaften (z.B. nur positive Werte, deutliche Schiefe) nicht zu transformieren, um Normalverteilung zu erreichen, sondern durch eine geeignete Verteilung zu modellieren (z.B. Gammaverteilung) und hierfür ein spezielles Regressionsmodell zu verwenden. Mit Hilfe *generalisierter linearer Modelle* (GLM) lassen sich explizit eine Reihe von Verteilungen der Zielvariablen effektiv modellieren. Zulässig sind Verteilungen aus der Exponentialfamilie. In der Praxis relevant sind vor allem:

- Binomialverteilung für binäre Daten
- Multinomialverteilung für kategoriale Daten
- Poissonverteilung für Zähldaten
- Gammaverteilung für stetige, positive und schiefe Daten

Das ALM mit normalverteilter Zielvariable stellt einen Spezialfall des GLMs dar, da die Normalverteilung ebenfalls zur Exponentialfamilie gehört. Da im vorliegenden Experiment eine binäre Größe (korrekte Reaktion vs. keine/falsche Reaktion auf einen Stimulus) analysiert wird, beschränkt sich die folgende Beschreibung auf

ein GLM für eine binomialverteilte Zielgröße, d.h.

$$y = \begin{cases} 1 & \text{mit Wahrscheinlichkeit } \pi \\ 0 & \text{mit Wahrscheinlichkeit } 1 - \pi. \end{cases}$$

Ziel ist in diesem Fall die Schätzung des Einflusses der Kovariaten auf die bedingte Wahrscheinlichkeit (a-posteriori Wahrscheinlichkeit)

$$\pi_i = P(y_i = 1 | x_{i1}, \dots, x_{ik}) = \mathbb{E}(y_i | x_{i1}, \dots, x_{ik})$$

der i -ten Beobachtung (Fahrmeir et al., 2007). In Erweiterung des ALM, wird zwischen der Zielvariable und den Kovariaten folgender Zusammenhang angenommen:

$$\mathbb{E}(y_i | x_{i1}, \dots, x_{ik}) = h(\mathbf{x}'_i \boldsymbol{\beta}),$$

bzw.

$$\pi_i = h(\eta_i), \tag{2.16}$$

mit *linearem Prädiktor* $\eta_i = \mathbf{x}'_i \boldsymbol{\beta}$, $\boldsymbol{\beta} = (\beta_0, \dots, \beta_k)'$ und $\mathbf{x}_i = (1, x_{i1}, \dots, x_{ik})'$. h wird *Responsefunktion* genannt. Für $h(x) = x$ erhält man das ALM. Mit Hilfe der Umkehrfunktion h^{-1} kann η_i geschrieben werden als

$$\eta_i = h^{-1}(\pi_i) = g(\pi_i). \tag{2.17}$$

g wird auch als *Linkfunktion* bezeichnet. Als Responsefunktion wird in dieser Arbeit die logistische Verteilungsfunktion

$$\pi = h(\eta) = \frac{e^\eta}{1 + e^\eta} \tag{2.18}$$

verwendet. Abbildung 2.20 zeigt den Verlauf der Responsefunktion im logistischen Modell in Abhängigkeit von η . Die Transformation durch h bewirkt die Eingrenzung des Wertebereichs des sonst nicht beschränkten linearen Prädiktors auf das Einheitsintervall, d.h. $h(\mathbf{x}'_i \boldsymbol{\beta}) \in [0, 1]$ für $\mathbf{x}'_i \boldsymbol{\beta} \in \mathbb{R}$. Damit wird stets sichergestellt, dass $0 \leq \pi_i \leq 1$. Bei der Wahl von h gemäß 2.18 ergibt sich für die Linkfunktion

$$\eta = g(\pi) = \log\left(\frac{\pi}{1 - \pi}\right). \tag{2.19}$$

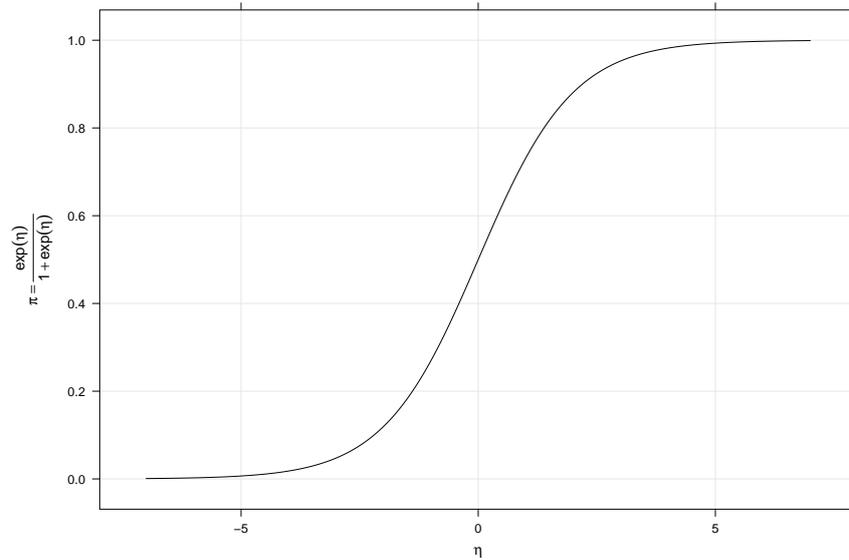


Abbildung 2.20: Logistische Verteilung: Responsefunktion h für binäre Daten.

Der Ausdruck 2.19 wird *Logit* genannt. Das Verhältnis von π zur Gegenwahrscheinlichkeit $1 - \pi$ wird auch als *Odds* (Chance), bzw. in logarithmierter Form als *log-Odds* bezeichnet. η stellt nun ein lineares Modell für die *log-Odds* dar. Die *Odds* entsprechen dem multiplikativen Modell

$$\frac{\pi_i}{1 - \pi_i} = \frac{P(y_i = 1 | \mathbf{x}_i)}{P(y_i = 0 | \mathbf{x}_i)} = e^{\beta_0} \cdot e^{\beta_1 x_{i1}} \cdot \dots \cdot e^{\beta_k x_{ik}}.$$

Damit wird eine Interpretation der Koeffizienten β_i möglich: Erhöht sich x_{i1} um 1 auf $x_{i1} + 1$, so gilt für das Verhältnis der Chancen

$$\frac{P(y_i = 1 | x_{i1} + 1, \dots)}{P(y_i = 0 | x_{i1} + 1, \dots)} / \frac{P(y_i = 1 | x_{i1}, \dots)}{P(y_i = 0 | x_{i1}, \dots)} = e^{\beta_1} \quad (2.20)$$

(Fahrmeir et al., 2007). Angenommen $y_i = 1$ kodiert das Vorhandensein einer Krankheit, dann ist $P(y_i = 1)$ die Wahrscheinlichkeit für das Auftreten dieser Krankheit. Eine Kovariate x_{i1} sei diskret und kodiere ein bestimmtes Merkmal, wie z.B. Raucher/Nicht-Raucher. Es sei weiter angenommen, dass $\beta_1 = 2$ und damit $\exp(\beta_1) = 7,4$. Die Chance, bzw. das Risiko für die Krankheit erhöht sich bei Änderung von x_{i1} um 1 damit um das Siebenfache.

Generalisierte lineare gemischte Modelle (GLMM)

Analog zum LMM wird für ein GLMM der lineare Prädiktor η_i um zufällige Effekte \mathbf{b}_i erweitert:

$$\boldsymbol{\eta}_i = \mathbf{X}_i\boldsymbol{\beta} + \mathbf{Z}_i\mathbf{b}_i. \quad (2.21)$$

Die unabhängigen, subjektspezifischen Zielvariablen $\mathbf{y}_i|\mathbf{b}_i$ folgen für binäre Daten jeweils einer Binomialverteilung und der bedingte Erwartungswert $\boldsymbol{\pi}_i = \mathbb{E}(\mathbf{y}_i|\mathbf{b}_i)$ für Proband i ist mit dem linearen Prädiktor 2.21 wieder über die Responsefunktion h (logistische Verteilung) verknüpft durch

$$\boldsymbol{\pi}_i = \mathbb{E}(\mathbf{y}_i|\mathbf{b}_i) = h(\boldsymbol{\eta}_i).$$

Die zufälligen Effekte werden wie im LMM als normalverteilt angenommen mit $\mathbf{b}_i \sim \mathcal{N}(\mathbf{0}, \mathbf{D})$.

Ausgangspunkt für die Parameterschätzung ist, analog dem LMM, die Likelihood-Funktion des marginalen Modells, welche sich durch Integration der bedingten Likelihood ergibt

$$L(\boldsymbol{\beta}, \boldsymbol{\alpha}) = \int p(\mathbf{y}|\boldsymbol{\beta}, \mathbf{b})p(\mathbf{b}|\boldsymbol{\alpha})d\mathbf{b}$$

(Fahrmeir et al., 2007). Der Faktor $p(\mathbf{y}|\boldsymbol{\beta}, \mathbf{b})$ ist das Produkt aus n unabhängigen Likelihoods pro Subjekt, welche der entsprechenden Dichtefunktion aus der gewählten Exponentialfamilie entsprechen. Anders als im LMM führt dies zu keiner analytischen Lösung des Integrals, weshalb die Parameterschätzung komplexer wird. Der im Paket **lme4** implementierte Ansatz besteht darin, das Integral für die marginale Likelihood durch eine Laplace-Approximation zu lösen. Die Maximierung bezüglich $\boldsymbol{\beta}$ und \mathbf{b}_i erfolgt über eine iterative, gewichtete, penalisierte KQ-Schätzung (engl. penalized iteratively reweighted least squares, PIRLS). Details des Verfahrens sind in Fahrmeir et al. (2007) zu finden.

Die geschätzten Parameter der festen und zufälligen Effekte sind wieder approximativ normalverteilt. Für Tests auf Signifikanz der festen Effekte kann ein approximativer Wald-Test durchgeführt werden, allerdings können die p-Werte für kleine Stichproben und unbalancierte Designs stark verfälscht sein. Eine Alternative bestünde, wie für LMMs, in der Bestimmung der p-Werte über MCMC-Sampling. In der aktuellen Version des **lme4**-Pakets ist das MCMC-Sampling zur Zeit noch nicht implementiert, weshalb auf Wald-Tests zurückgegriffen wird. Diese Vorgehensweise ist für die vorliegenden Daten weniger kritisch, da eine relativ

große Stichprobe zur Verfügung steht. Die zufälligen Effekte können mit LQ-Tests auf Signifikanz überprüft werden.

2.4.3 Ergebnisse

Laborversuch

Zunächst wird überprüft, ob die Koinzidenz einer Spindel mit einem Stimulus einen Einfluss auf die Reaktionszeit hat. Dazu werden ungültige Reaktionen, wie die Benutzung der falschen Hand, zu schnelle Reaktionen (< 200 ms) und keine Reaktion aus der Analyse ausgeschlossen. Die Aufteilung der Gesamtstichprobe auf die Faktoren *Bedingung* (3), *Stimulus* (2) und *Koinzidenz* (2) ist in Abbildung 2.21 mit Hilfe eines *mosaicplots* dargestellt. Die Kachelgrößen geben die

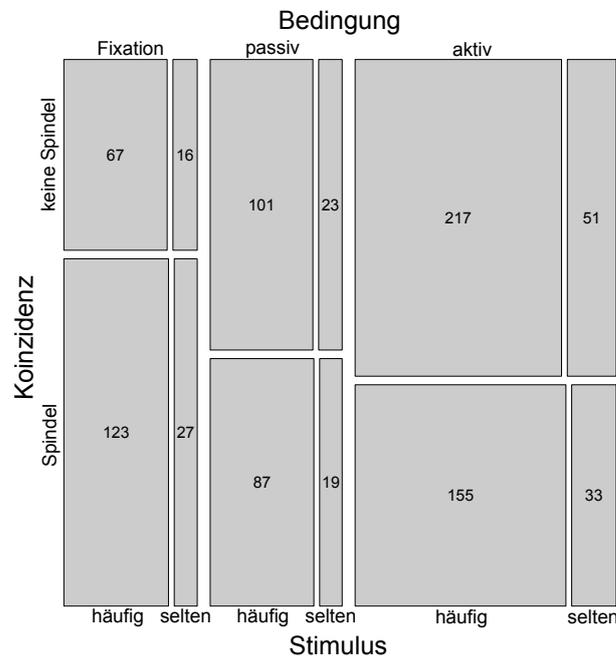


Abbildung 2.21: Mosaicplot: Die Kacheln stellen relative Häufigkeiten in den Faktorstufen dar. Die mittlere Anzahl an Stimuli je Proband und Faktorstufenkombination ist in den Kacheln angegeben.

relative Stichprobengröße sowohl zwischen den Stufen eines Faktors als auch zwischen verschiedenen Faktoren an. Die Werte in den Kacheln geben die mittleren Stichprobengröße je Proband an. Zu erkennen ist die längere Dauer der Bedingung *aktiv* und das 80/20-Verhältnis der Stimuli *häufig/selten*. Die Abnahme der Koinzidenzen eines Stimulus und einer Spindel bei Wechsel der Bedingung *Fixation* zu *aktiv* deutet auf eine Verringerung der Spindelaktivität hin, da die Stimulusrate über das Experiment konstant ist. Abbildung 2.22 zeigt die Spindelrate an

parieto-okzipitalen Elektroden pro Bedingung und experimentellem Durchgang und bestätigt den Abfall der Spindelaktivität von *Fixation* zu *aktiv*. Außerdem ist aus der Grafik ein leichter Anstieg im zweiten Block zu verzeichnen.

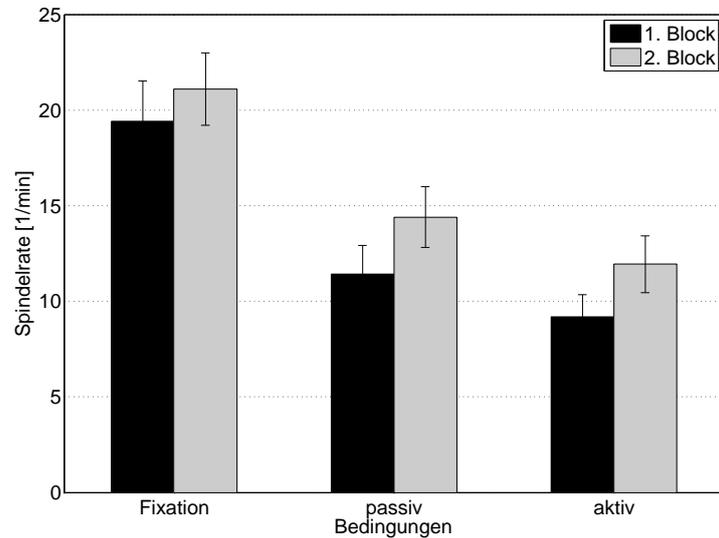


Abbildung 2.22: Spindelrate im Laborversuch für die verschiedenen experimentellen Bedingungen. Die Blöcke 1 und 2 werden hintereinander durchlaufen und enthalten jeweils alle drei experimentellen Bedingungen in randomisierter Reihenfolge. Ein Block dauert etwa 45 min. Die Grafik zeigt die über parieto-okzipitale Kanäle gemittelte Spindelrate.

Zunächst wird ein ALM für jeden Probanden bestimmt. Dies entspricht dem oben beschriebenen zweistufigen Vorgehen (s. 2.10). Damit werden die mittleren Effekte pro Faktorstufe und Proband sichtbar. Die Variation der Koeffizienten eines Faktors zwischen den Probanden gibt Aufschluss darüber ob dieser Faktor auch als zufälliger Effekt modelliert werden sollte. Abbildung 2.23 zeigt die Ergebnisse (geschätzter Koeffizient und Konfidenzintervall) für ein ALM pro Proband mit den Faktoren *Bedingung*, *Stimulus* und *Koinzidenz*, ohne Interaktionen. Für das ALM wird eine Dummykodierung verwendet, bei der folgende Faktorstufen die Referenz bilden:

- *Bedingung/Fixation*
- *Stimulus/häufig*

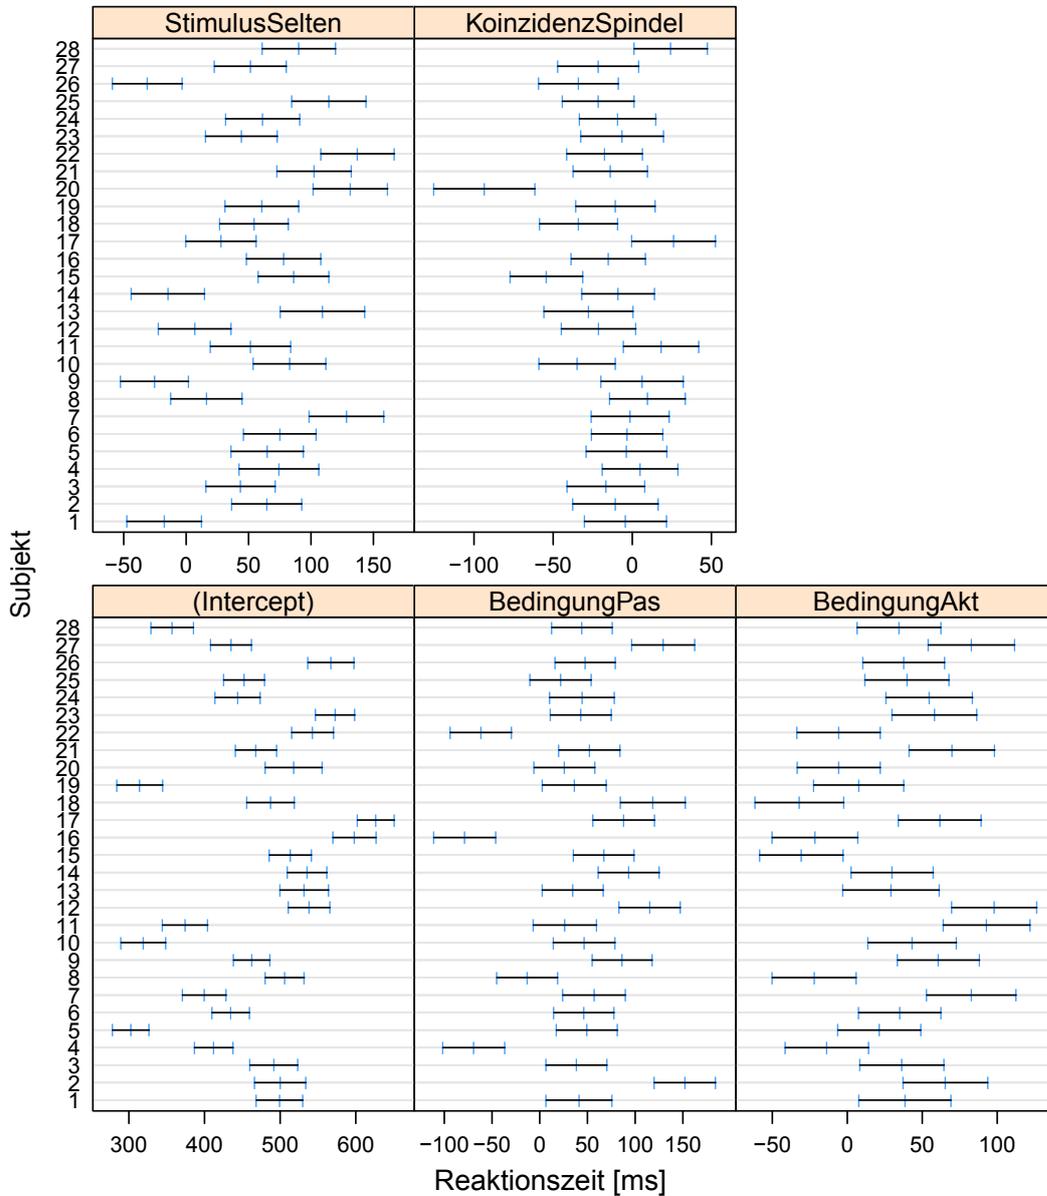


Abbildung 2.23: Koeffizienten individueller ALMs für alle Faktoren im Modell. Keine Interaktion zwischen den Faktoren. Für eine Interpretation der Grafik s. Text.

- *Koinzidenz/keine Spindel*

Die berechneten Koeffizienten geben die mittlere Abweichung der übrigen Faktorstufen von der Referenz an. Der Wert für die Referenz selbst ist in der Konstante festgehalten. Diese Kodierung wird für die weiteren Analysen beibehalten. In [Abbildung 2.23](#) ist die starke Streuung der mittleren Reaktionszeit zwischen den

Probanden (Intercept) gut zu erkennen. Die Bedingungen *passiv* und *aktiv* weisen ebenfalls starke individuelle Unterschiede auf, mit einer im Mittel höheren Reaktionszeit gegenüber *Fixation*. Bei den meisten Probanden lassen sich auch höhere Reaktionszeiten für den seltenen Stimulus erkennen. Auch hier gibt es deutliche interindividuelle Unterschiede. Eine Koinzidenz eines Stimulus und einer Spindel lässt eine geringere Reaktionszeit, mit weniger starken individuellen Unterschieden, erkennen. Für alle Faktoren zeichnet sich ein – wenn auch unterschiedlich hoch – Populationseffekt ab. Da es für die Faktoren *Bedingung* und *Stimulus* deutliche und für den Faktor *Koinzidenz* erkennbare individuelle Unterschiede gibt, wird im weiteren Vorgehen auch ein zufälliger Effekt für jeden Faktor eingeführt. Die Notwendigkeit des entsprechenden zufälligen Faktors für eine bessere Modellanpassung wird über LQ-Tests geprüft. Vorausgesetzt wird allerdings ein zufälliger Effekt für die Konstante, da die starke Streuung zwischen den Probanden dies impliziert.

Für die Struktur der Kovarianzmatrix \mathbf{D} der zufälligen Effekte spielen die Abhängigkeiten zwischen den zufälligen Effekten ebenfalls eine wichtige Rolle. Um diese Korrelationen abzuschätzen, werden paarweise Scatterplots für die berechneten Koeffizienten aus den individuellen ALMs angefertigt. Die resultierende Grafik ist in Abbildung 2.24 zu sehen. Es sind keine ausgeprägten Korrelationen erkennbar, weshalb für die Kovarianzmatrix eine einfache Diagonalmatrix verwendet wird, bei der alle Faktoren als unabhängig angenommen werden.

Für die Bestimmung eines LMMs für alle Probanden wird zunächst die Struktur der Mittelwerte im Modell analysiert. Interaktionen zwischen allen Faktoren sind theoretisch möglich, z.B. kann der Einfluss der Koinzidenz auf die Reaktionszeit andersartig für die beide Stimulustypen ausfallen. Zusätzlich kann die Änderung der visuellen Aufmerksamkeit in den Bedingungen einen Einfluss auf den Koinzidenzeffekt ausüben. Deshalb wird zunächst ein gesättigtes Modell mit allen Interaktionstermen angenommen. Ein zufälliger Effekt für die Konstante, d.h. der mittlere Niveauunterschied zwischen den Probanden, wird mit in das Modell aufgenommen. Dieses Modell beinhaltet 14 freie Parameter: 12 Koeffizienten der festen Effekte, einen Varianzterm des zufälligen Effekts der Konstante und die Fehlervarianz. Die Ergebnisse der REML-Schätzung sind in Tabelle 2.7 aufgelistet. Zur Bestimmung der Irrtumswahrscheinlichkeiten kommt das im Abschnitt 2.4.2 beschriebene MCMC-Sampling zum Einsatz.

Alle Haupteffekte, sowie die Interaktion *Stimulus/selten*Koinzidenz/Spindel*, sind signifikant. Die Standardabweichung des zufälligen Effektes liegt deutlich

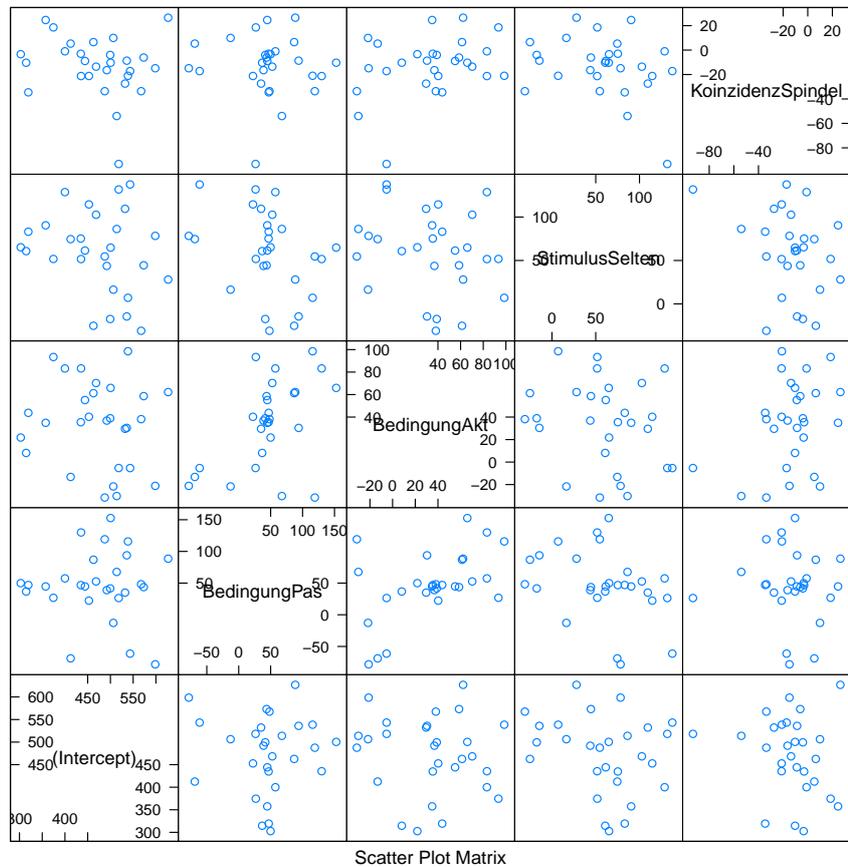


Abbildung 2.24: Scatterplot der Koeffizienten individueller ALMs. Es sind keine ausgeprägten Korrelationen zwischen den Faktoren erkennbar.

über Null und ist deshalb relevant für das Modell.

Im nächsten Schritt werden die nicht signifikanten Interaktionsterme aus dem Modell entfernt. Mit dem reduzierten Modell (*Modell 1b*) werden sukzessive zufällige Effekte für jeden der drei festen Effekte hinzugefügt, um individuelle Merkmalsausprägungen in den einzelnen Faktoren zu berücksichtigen. Im Detail enthalten die Modelle die folgenden unabhängigen, zufälligen Effekte:

- Modell 2: *Konstante + Bedingung*
- Modell 3: *Konstante + Bedingung + Stimulus*
- Modell 4: *Konstante + Bedingung + Stimulus + Koinzidenz*

Der Vergleich der Modelle erfolgt über LQ-Tests. Die Ergebnisse sind in Tabelle 2.8 dargestellt. Die Tabelle zeigt, dass jeder weitere zufällige Effekt eine Verbesserung

Zufällige Effekte				
Gruppierung: Subjekte				
	Konstante	Residuum		
StdAbw	83,02	177,44		
Stichprobengröße: 25720, Subjekte: 28				
Feste Effekte: RT ~ Bedingung*Stimulus*Koinzidenz				
Effekt	Schätzung	Std. Fehler	t-Wert	pMCMC
Konstante	471,50	16,22	29,08	0,0001
BedPas	49,53	5,30	9,34	0,0001
BedAkt	32,54	4,72	6,90	0,0001
StimSelt	44,46	9,41	4,73	0,0001
KoinzSpin	-15,96	5,18	-3,08	0,0034
BedPas:StimSelt	9,25	12,18	0,76	0,4473
BedAkt:StimSelt	6,09	10,75	0,57	0,5709
BedPas:KoinzSpin	-7,08	7,10	-1,00	0,3186
BedAkt:KoinzSpin	3,04	6,24	0,49	0,6267
StimSelt:KoinzSpin	24,65	11,80	2,09	0,0367
BPas:StSelt:KoSpin	-15,49	16,47	-0,94	0,3471
BAkt:StSelt:KoSpin	-4,36	14,42	-0,30	0,7624

Tabelle 2.7: Ergebnisse für Modell 1 (AIC=339480, logLik=-169726). Alle Faktoren sowie die Interaktion *Stimulus*Koinzidenz* sind signifikant.

erzielt. Modell 4 mit einem zufälligen Effekt für jeden festen Effekt liefert die beste Anpassung an die Daten. Die größten Verbesserungen werden mit zufälligen Effekten für die Faktoren *Bedingung* und *Stimulus* erzielt, wie in Abbildung 2.23 bereits erkennbar.

Die geschätzten Parameter für das finale Modell 4 sowie Signifikanztests für die festen Effekte sind in Tabelle 2.9 aufgelistet. Bis auf die Interaktion, welche tendenziell auf eine Abschwächung des Koinzidenzeffektes für seltene Stimuli hinweist, sind alle Terme signifikant.

	df	AIC	logLik	Test	Quotient	p-Wert
Modell 1b	8	339538	-169761			
Modell 2	10	339210	-169595	1 vs 2	332,31	<,0001
Modell 3	11	339042	-169510	2 vs 3	170,00	<,0001
Modell 4	12	339022	-169499	3 vs 4	21,42	<,0001

Tabelle 2.8: Likelihood-Quotienten-Test. Modell 4 mit vier zufälligen Effekten bildet die Labordaten am besten ab.

Zufällige Effekte: Kovarianzmatrix D : diagonal
 Gruppierung: Subjekte

	Konstante	BedPas	BedAkt	StimSelt	KoinzSpin	Residuum
StdAbw	82,66	50,55	32,84	44,04	18,22	174,88

Stichprobengröße: 25720, Subjekte: 28

Feste Effekte: $RT \sim \text{Bedingung} + \text{Stimulus} * \text{Koinzidenz}$

Effekt	Schätzung	Std. Fehler	t-Wert	pMCMC
Konstante	471,52	15,87	29,72	0,0001
BedPas	46,36	10,05	4,61	0,0001
BedAkt	34,41	6,78	5,07	0,0001
StimsSelt	56,09	9,23	6,08	0,0001
KoinzSpin	-14,08	4,33	-3,26	0,0034
StimSelt:KoinzSpin	7,68	5,94	1,29	0,1892

Tabelle 2.9: Ergebnisse für das finale Modell 4. AIC=338987, logLik=-169481

Die Regressionsgleichung eines Probanden i für Modell 4

$$\mathbf{y}_i = \mathbf{X}_i \boldsymbol{\beta} + \mathbf{Z}_i \mathbf{b}_i + \boldsymbol{\varepsilon}_i$$

hat eine Designmatrix \mathbf{X}_i mit Dimension $(n_i \times 6)$. Die 6 Faktoren bilden die dummykodierte Kontraste. Dementsprechend ist $\boldsymbol{\beta}$ ein (6×1) Vektor mit festen Effekten. Die Designmatrix \mathbf{Z}_i der zufälligen Effekte hat Dimension $(n_i \times 5)$ und der Vektor der zufälligen Effekte \mathbf{b}_i hat die Dimension (5×1) . Die Kovarianzmatrix D hat die Struktur $\text{diag}(d_1, \dots, d_5)$ mit den Varianzen aus Tabelle 2.9 auf der Diagonalen. Der Modellfehler hat die Dimension $(n_i \times 1)$ und die Kovarianzmatrix $\boldsymbol{\Sigma}_i = 174,88^2 \mathbf{I}_{n_i}$.

Mit den *empirical Bayes* Schätzern für $\hat{\mathbf{b}}_i$ und den ermittelten festen Effekten, können die Ausprägungen in allen Faktoren für jeden Probanden über das aufgestellte Modell 4 vorhergesagt werden. Abbildung 2.25 zeigt einen Boxplot der so bestimmten individuellen Profile und gibt einen Überblick über die Effektstärken der einzelnen Faktoren sowie deren interindividuelle Streuung. Gegenüber der Bedingung *Fixation* erhöht sich die Reaktionszeit für die Bedingungen *passiv* und *aktiv* deutlich. Die Reaktionszeiten auf den seltenen Stimulus sind ebenfalls langsamer als auf den häufigen. Bei Koinzidenz einer Spindel und einem Stimulus verringert sich die Reaktionszeit.

Um zu überprüfen, ob das gefundene Modell die Daten adequat repräsentiert,

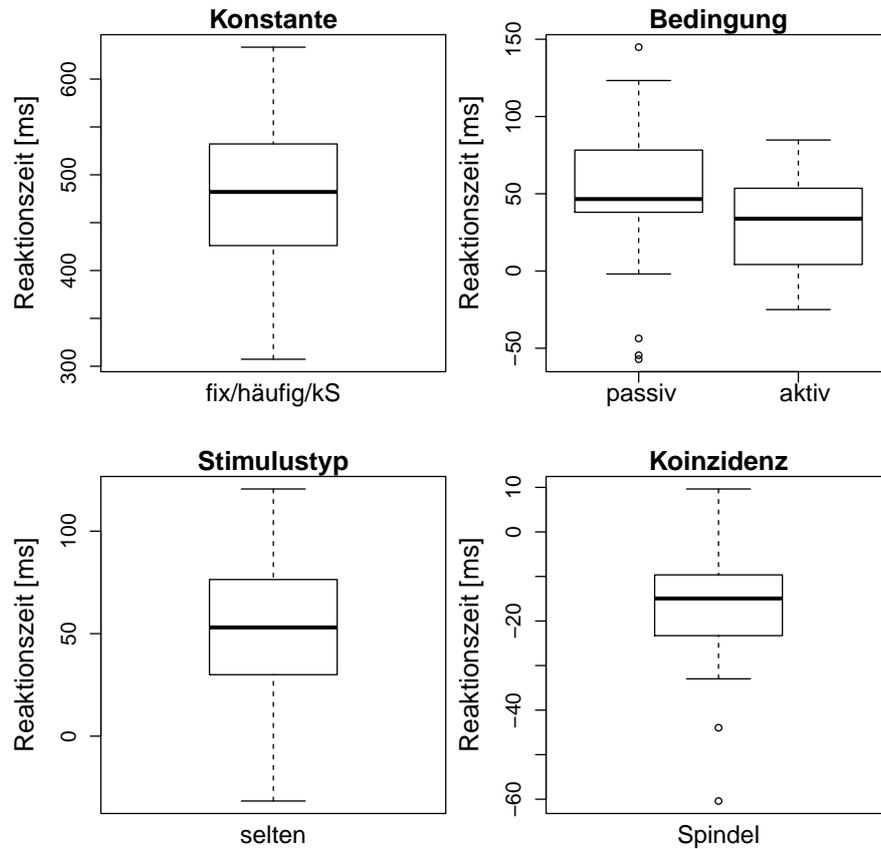


Abbildung 2.25: Boxplots der geschätzten Parameter je Subjekt ($\hat{\beta} + \hat{b}_i$).

wird die Annahme einer Normalverteilung der Residuen überprüft. Dazu eignet sich ein Quantil-Quantil-Plot bei dem die theoretisch erwarteten Quantile der Normalverteilung mit denen der Residuen verglichen werden. Sind die Residuen normalverteilt, liegen alle Werte auf einer Diagonalen. Abbildung 2.26 (links) zeigt eine starke Abweichung der Residuen von der Normalverteilung, vor allem für hohe Reaktionszeiten (rechter Bildbereich). Es existieren also zahlreiche Ausreißer, mit langen Reaktionszeiten, die mit dem Modell nicht gut erklärt werden können.

Eine schiefe Verteilung für Reaktionszeiten wird recht häufig in Experimenten beobachtet. Deshalb werden die Daten häufig transformiert, um sie besser mit einer Normalverteilung beschreiben zu können. Üblich sind das Logarithmieren $\log(RT)$ und der Kehrwert der Reaktionszeit $1/RT$.

Modell 4 wird mit den transformierten Daten noch einmal berechnet, um die Effektivität beider Transformationen für vorliegende Daten zu überprüfen. Abbildung 2.26 (Mitte und rechts) zeigt QQ-Plots für beide Transformationen. Die

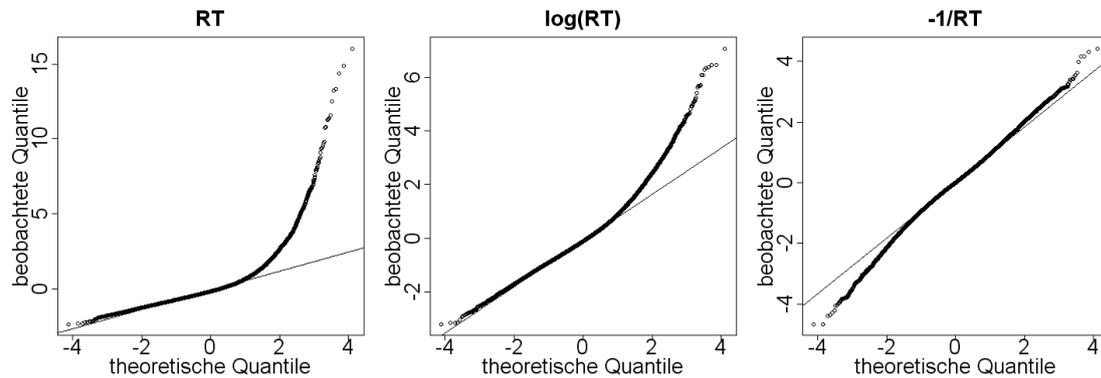


Abbildung 2.26: Links: Quantil-Quantil-Plot der Residuen aus Modell 4. Eine deutliche Rechtsschiefe ist zu erkennen. Mitte u. Rechts: transformierte Daten. Die Rechtsschiefe nimmt ab, am deutlichsten bei der Kehrwert-Transformation.

Rechtsschiefe kann mit der Kehrwert-Transformation nahezu vollständig beseitigt werden. Mit dieser Transformation sind die Verteilungsannahmen also wesentlich besser erfüllt. Die vorherigen Analysen sind trotzdem ohne Transformation ausgeführt, da die Regressionskoeffizienten der nicht-transformierten Daten Reaktionszeiten in Millisekunden darstellen und hierdurch die Interpretation der Ergebnisse wesentlich einfacher ist. Ein Test auf Signifikanz der festen Effekte für den Kehrwert der Reaktionszeit liefert die gleichen Ergebnisse wie für die untransformierten Daten, mit der Ausnahme, dass die Interaktion *Stimulus*Koinzidenz* signifikante Ergebnisse zeigt ($pMCMC = 0.0028$), was zu einer Abschwächung des Koinzidenzeffektes bei seltenen Stimuli führt.

Die Detektionsraten der Stimuli in Abhängigkeit verschiedener Faktoren werden mit Hilfe der GLMMs analysiert. Unterschieden wird zwischen einer korrekten Detektion bzw. Reaktion auf einen Stimulus, wenn innerhalb eines Zeitfensters von 200 ms bis 2000 ms und mit der richtigen Hand reagiert wird. Falsche Reaktionen (Verwechslung der Hand) bzw. keine Reaktionen ($RT > 2s$ oder nicht reagiert) werden zu falschen Detektionen zusammengefasst. Die getrennte Analyse der beiden Typen ist nicht möglich, da hierfür eine zu kleine Stichprobe vorliegt. Die binäre Zielvariable folgt damit einer Binomialverteilung und ein generalisiertes LMM mit dem Logit als Linkfunktion kann zur Analyse verwendet werden. Die Mittelwertstruktur aus Modell 4 für die Reaktionszeiten wird als Ansatz für das GLMM verwendet. Die zufälligen Effekte werden als unabhängig angenommen. Es wird erneut mit Hilfe von LQ-Tests die Relevanz zufälliger Effekte für die Faktoren *Bedingung*, *Stimulus* und *Koinzidenz* geprüft. Der zufällige Effekt der

Konstante ist in jedem Modell enthalten. Tabelle 2.10 listet die Ergebnisse der LQ-Tests auf. Modell 3 mit zufälligen Effekten für *Konstante*, *Bedingung* und *Stimulus* liefert die kompakteste Beschreibung der Daten. Die Hinzunahme des zufälligen Effekts für *Koinzidenz* führt zu keiner Modellverbesserung. Tabelle 2.11

	df	AIC	logLik	Test	Quotient	p-Wert
Modell 1	7	8366,1	-4176,0			
Modell 2	9	8116,9	-4049,4	1 vs 2	253,18	<,0001
Modell 3	10	8048,6	-4014,3	2 vs 3	70,25	<,0001
Modell 4	11	8048,9	-4013,4	3 vs 4	1,76	0,1843

Tabelle 2.10: Likelihood-Quotienten-Test. Modell 3 mit drei zufälligen Effekten (*Konstante*, *Bedingung*, *Stimulus*) ist das beste Modell für das GLMM.

zeigt die Parameterschätzungen der festen und zufälligen Effekte für Modell 3. Die Irrtumswahrscheinlichkeiten werden über approximative Wald-Tests ermittelt. Alle Faktoren haben einen signifikanten Einfluss auf die Wahrscheinlichkeit

Zufällige Effekte: Kovarianzmatrix *D*: diagonal

Gruppierung: Subjekte

	Konstante	BedPas	BedAkt	StimSelt
StdAbw	0,548	0,401	0,733	0,619

Stichprobengröße: 26912, Subjekte: 28

Feste Effekte: $RT \sim \text{Bedingung} + \text{Stimulus} * \text{Koinzidenz}$

Effekt	Schätzung	Std. Fehler	z-Wert	p-Wert
Konstante	3,958	0,141	28,091	<,0001
BedPas	-0,249	0,125	-1,992	0,0464
BedAkt	-0,164	0,167	-0,986	0,3243
StimsSelt	-1,582	0,148	-10,725	<,0001
KoinzSpin	0,457	0,095	4,812	<,0001
StimSelt:KoinzSpin	-0,244	0,134	-1,826	0,0679

Tabelle 2.11: GLMM: Ergebnisse für das finale Modell 3. AIC=8049, logLik=-4014

einer korrekten Reaktion. Nur die Bedingung *aktiv* zeigt keinen Unterschied zu *Fixation* und die Interaktion *Stimulus/Selten*Koinzidenz/Spindel* liegt nur knapp oberhalb des Signifikanzniveaus von 0,05. Relevant für die Untersuchung des Einflusses der Spindeln auf die Detektionsrate ist der Faktor *Koinzidenz*. Ein Wert von 0,457 besagt, dass die Chance für eine korrekte Reaktion, bei Ertönen des Stimulus während einer Spindel, um $\exp(0,457) = 1,58$ steigt im Vergleich zu

einem Stimulus, der außerhalb einer Spindel ertönt. Für seltene Stimuli ist die Wahrscheinlichkeit für korrekte Reaktionen zudem deutlich geringer als für häufige. Um die Implikationen von Modell 3 zu visualisieren, werden die bedingten Wahrscheinlichkeiten für eine korrekte Reaktion $P(y_i = 1 | \mathbf{b}_i, \mathbf{x}_i)$ mit Hilfe des Modells für jeden Probanden vorhergesagt (empirical Bayes Schätzer). Abbildung 2.27 zeigt Boxplots der vorhergesagten bedingten Wahrscheinlichkeiten, aufgeschlüsselt nach den drei Faktoren des Modells. Gut zu erkennen ist die höhere Detektionsra-

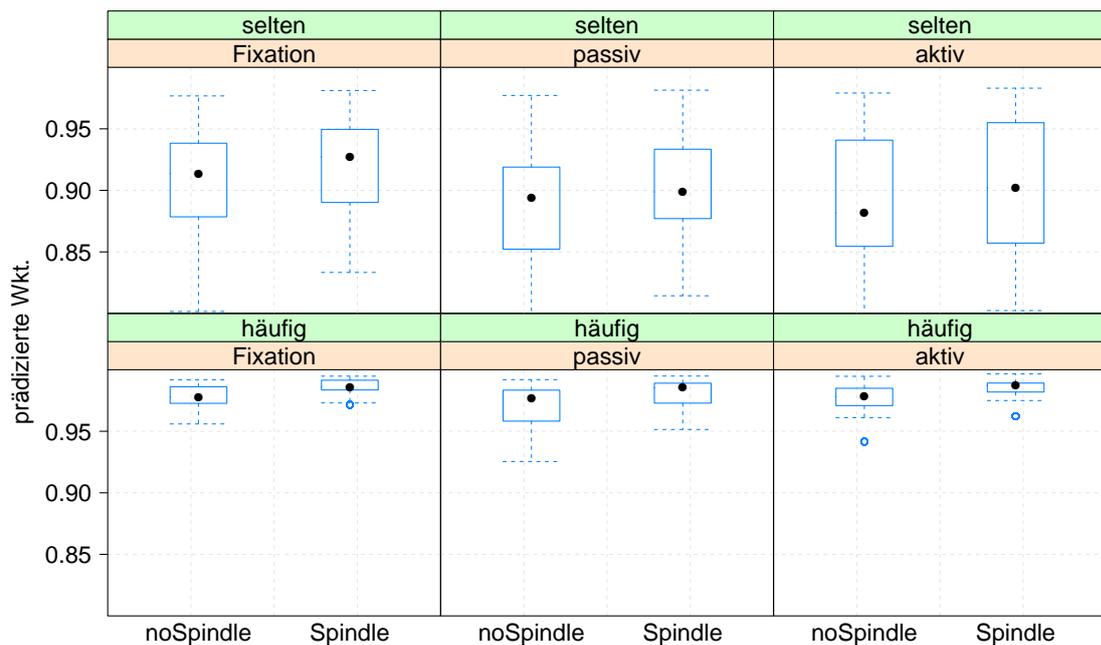


Abbildung 2.27: Vorhergesagte Wahrscheinlichkeiten für korrekte Reaktionen mittels generalisiertem linearem Modell

te bei Koinzidenz mit einer Spindel für beide Stimulustypen, was der signifikant positive Faktor *Koinzidenz* in Tabelle 2.11 ebenfalls nahelegt. Der hier scheinbar stärkere Effekt für seltene Stimuli rührt daher, dass bei der logistischen Regression die Auswirkung eines Effektes auf die bedingte Wahrscheinlichkeit abhängig von dieser Wahrscheinlichkeit selbst ist. An den Definitionsrändern (zu 0 oder 1 hin) schwächt sich der Effekt ab, während er im Bereich 0,5 am größten ist (Hoetker, 2007). Diese Tatsache erklärt, warum die Detektionsrate für seltene Stimuli, welche eine mittlere Wahrscheinlichkeit näher zu 0,5 haben, scheinbar stärker von der Koinzidenz mit einer Spindel beeinflusst werden obwohl keine signifikante Interaktion zwischen *Stimulus* und *Koinzidenz* vorliegt.

Fahrversuch

Für die Analyse des Fahrversuchs entfällt der Faktor *Bedingung*, sodass nur noch die Faktoren *Stimulus* (2) und *Koinzidenz* (2) im Modell enthalten sind. Zunächst werden die Einflüsse der experimentellen Faktoren auf die Reaktionszeiten diskutiert. Basierend auf den Ergebnissen des Laborversuchs wird ein LMM mit gesättigter Mittelwertstruktur für die festen Effekte (*Stimulus***Koinzidenz*) sowie unabhängige zufällige Effekte für die Konstante, *Stimulus* und *Koinzidenz* verwendet. Die Designmatrix enthält wie im Laborversuch dummykodierte Faktoren mit *Stimulus/häufig* und *Koinzidenz/keineSpindel* als Referenzkategorie. Für jede Faktorstufe steht eine wesentlich größere Stichprobe zur Verfügung, da der Faktor *Bedingung* wegfällt und das Experiment nun vier Stunden anstatt 1,5 Stunden dauert. Eine Übersicht über die mittlere Stichprobengröße pro Proband gibt Tabelle 2.12.

		Stimulus	
		häufig	selten
Koinzi- denz	nein	1187	305
	ja	471	114

Tabelle 2.12: Mittlere Anzahl an Stimuli je Proband in den jeweiligen Faktorstufen für das Fahrexperiment.

Die geschätzten Parameter sowie Ergebnisse der Signifikanztests für die festen Effekte sind in Tabelle 2.13 aufgelistet. Sämtliche festen Effekte sind signifikant. Die zufälligen Effekte weisen Varianzen deutlich verschieden von Null auf. Die Ergebnisse aus dem Fahrversuch decken sich mit den Laborergebnissen. Neben einer generellen Verlangsamung der Reaktionszeit in der Realfahrt (vgl. Konstante) sind die Effekte für *Stimulus* und *Koinzidenz* stärker als im Labor. Durch die signifikante Interaktion schwächt sich der Effekt der Koinzidenz für die seltenen Töne stark ab. Die höhere Varianz für den zufälligen Effekt der Konstante zeigt, dass die individuellen Unterschiede in der Reaktionszeit noch größer als im Labor sind.

Abbildung 2.28 zeigt einen Boxplot der individuellen Profile, bestimmt aus dem Zusammenwirken der festen Effekte $\hat{\beta}$ und den individuellen Abweichungen $\hat{\mathbf{b}}_i$. Die Koinzidenz mit einer Spindel hat hauptsächlich für häufige Töne eine Auswirkung auf die Reaktionszeit.

Zufällige Effekte: Kovarianzmatrix **D**: diagonal
 Gruppierung: Subjekte

	Konstante	StimSelt	KoinzSpin	Residuum
StdAbw	111,23	47,41	15,53	283,71

Stichprobengröße: 46567, Subjekte: 24

Feste Effekte: $RT \sim Stimulus * Koinzidenz$

Effekt	Schätzung	Std. Fehler	t-Wert	pMCMC
Konstante	553,32	22,77	24,30	0,0001
StimsSelt	85,55	10,48	8,17	0,0001
KoinzSpin	-24,34	4,80	-5,08	0,0001
StimSelt:KoinzSpin	17,57	8,49	2,07	0,0388

Tabelle 2.13: Ergebnisse des LMMs für den Fahrversuch. AIC=658359, logLik=-329171

Die Detektionsraten werden, wie im Laborexperiment, mit einem GLMM analysiert. Die Klassifizierung korrekter und falscher Reaktionen ist identisch dem Vorgehen im Laborversuch. Es wird ein GLMM mit Binomialverteilung und Logit-Link verwendet. Ausgangspunkt ist ein Modell mit gesättigter Mittelwertstruktur der Faktoren *Stimulus* und *Koinzidenz* sowie einem zufälligen Effekt für die Konstante. Mit LQ-Tests wird die Relevanz zufälliger Effekte für die beiden Faktoren überprüft. Tabelle 2.14 zeigt die Ergebnisse. Modell 3 mit zufälligen Effekten für alle Faktoren liefert die beste Anpassung an die Daten.

	df	AIC	logLik	Test	Quotient	p-Wert
Modell 1	5	21432	-10711			
Modell 2	6	21289	-10638	1 vs 2	144,45	<,0001
Modell 3	7	21348	-10636	2 vs 3	4,41	0,0357

Tabelle 2.14: Likelihood-Quotienten-Test. Modell 3 mit drei zufälligen Effekten (*Konstante*, *Stimulus*, *Koinzidenz*) ist das beste Modell für das GLMM des Fahrversuchs.

Tabelle 2.15 listet die geschätzten Koeffizienten für Modell 3 auf. Seltene Stimuli haben eine geringere Wahrscheinlichkeit für eine korrekte Reaktion gegenüber häufigen Stimuli. Die Koinzidenz erhöht auch im Fahrversuch die Wahrscheinlichkeit korrekter Reaktionen, jedoch ist die Auswirkung dieses Faktors geringer als im Labor. Die Interaktion der beiden Faktoren ist nicht signifikant.

In Abbildung 2.29 sind Boxplots der vorhergesagten Wahrscheinlichkeiten für ei-

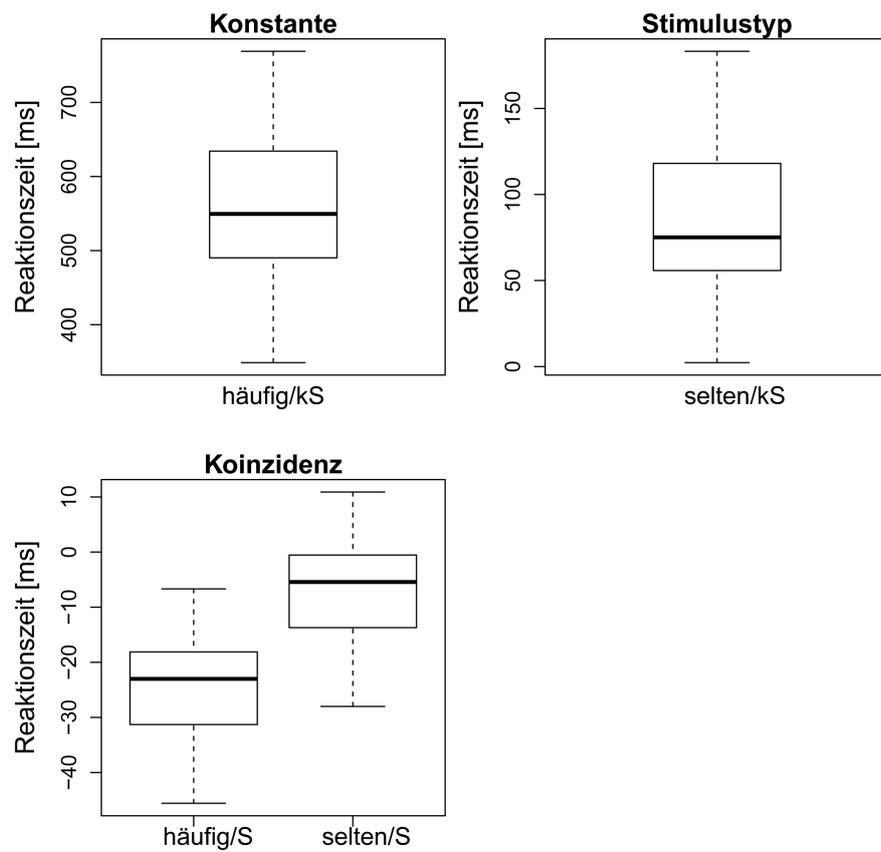


Abbildung 2.28: LMM: Boxplot der geschätzten subjektspezifischen Profile. Die Konstante gibt die Reaktionszeit in der Referenzkategorie an. Die beiden anderen Boxplots zeigen die relative Änderung der Reaktionszeit in den anderen Faktorstufen.

ne korrekte Reaktion dargestellt. Der Einfluss der Koinzidenz ist auch hier scheinbar stärker bei seltenen Stimuli (trotz nicht-signifikanter Interaktion), wobei die gleiche Anmerkung wie für die Labordaten gilt, dass sich der Effekt eines Faktors abschwächt je näher die Wahrscheinlichkeit bei 0 oder 1 liegt.

Zufällige Effekte: Kovarianzmatrix **D**: diagonal
 Gruppierung: Subjekte

	Konstante	StimSelt	KoinzSpin
StdAbw	0,806	0,528	0,201

Stichprobengröße: 49796, Subjekte: 24

Feste Effekte: $RT \sim Stimulus * Koinzidenz$

Effekt	Schätzung	Std. Fehler	z-Wert	p-Wert
Konstante	3,332	0,168	19,811	<,0001
StimsSelt	-1,542	0,118	-13,034	<,0001
KoinzSpin	0,268	0,079	3,377	0,0007
StimSelt:KoinzSpin	-0,097	0,096	-1,005	0,3150

Tabelle 2.15: GLMM: Ergebnisse für das finale Modell 3 des Fahrversuchs.
 AIC=21287, logLik=-10636

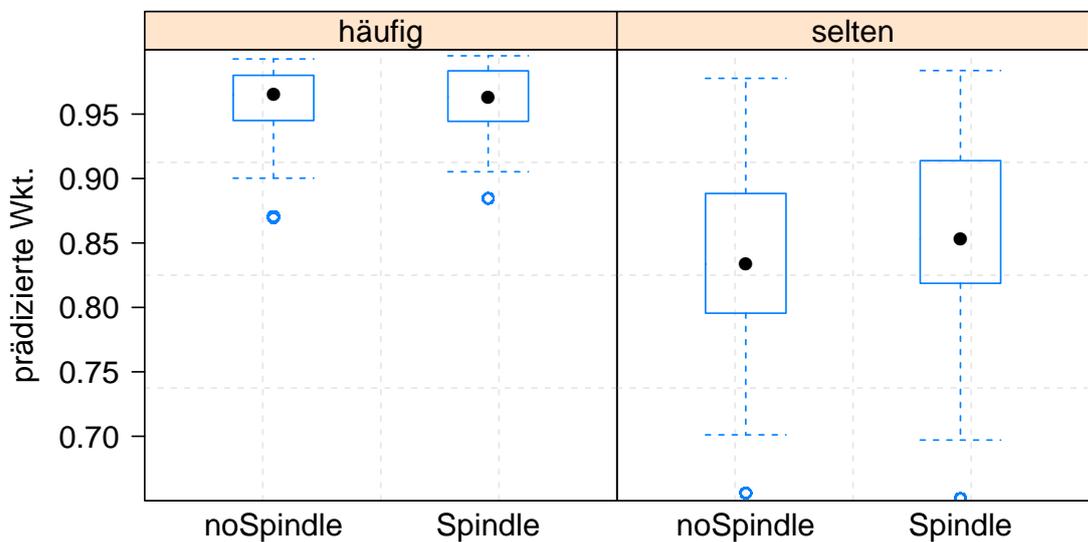


Abbildung 2.29: GLMM: Boxplots der prädizierten Wahrscheinlichkeiten für eine korrekte Reaktion unter allen Faktoren des Modells.

2.4.4 Diskussion

Der Einfluss der Alpha-Spindel auf die Reaktionszeit auf akustische Reize kann sowohl im Labor, als auch im Realverkehr gezeigt werden. Neurophysiologische Laborbefunde können somit in realistischen experimentellen Settings mit weniger kontrollierten Bedingungen nachgewiesen werden. Die Stärke der Effekte ist allerdings als schwach einzustufen. Im Labor reduziert die Koinzidenz einer Spindel mit einem Stimulus die Reaktionszeit im Mittel um 17 ms und im Fahrzeug um 24 ms. Von den vorgestellten Studien berichtet nur [Linkenkaer-Hansen et al. \(2004\)](#) einen Effekt der Prästimulus Alpha-Aktivität auf die Reaktionszeit, welcher bei ca. 50 ms liegt. Werte von 14 ms bzw. 24 ms liegen also in einem vergleichbaren Größenbereich. Generell zeigen die recherchierten Studien größere Effekte von Alpha-Aktivität auf die Stimulusverarbeitung, was vermutlich an sehr kontrollierten experimentellen Setups liegt, dafür aber ökologisch weniger valide Ergebnisse liefert. Z.B. wird in der Studie von [Foxy et al. \(1998\)](#) eine deutliche Korrelation zwischen Alpha-Power und dem Modalitätswechsel der Aufmerksamkeit beobachtet. Die jeweilige Fokussierung der Aufmerksamkeit auf visuelle bzw. akustische Reize wird allerdings experimentell gesteuert. Im vorliegenden Experiment ist ein ähnlicher Effekt beobachtbar, allerdings kann nicht sichergestellt werden, dass beim Auftreten einer Spindel auch eine hohe Aufmerksamkeit auf akustische Reize vorliegt, da dies nicht durch das Experiment gesteuert wird. Anderweitige mentale Okkupation ist ebenfalls möglich, was den Einfluss einer Spindel auf die Reaktionszeit herabsetzen kann.

Die kürzere Reaktionszeit bei Koinzidenz mit einer Spindel während einer Fahrt im Realverkehr, im Vergleich zu den Laborergebnissen, lässt sich vermutlich auf die höhere Beanspruchung der Primäraufgabe, dem Autofahren, im Vergleich zum Fahrsimulator zurückführen. Die höhere Beanspruchung zeigt sich auch in der Reaktionszeit für häufige Stimuli ohne Koinzidenz, welche sich im Fahrzeug um ca. 50 ms im Vergleich zur Fahrt im Fahrsimulator erhöht. Auf Grund einer begrenzten Gesamtkapazität (Ressourcenmodell von [Wickens \(1984\)](#)) sind für die Ausübung der Nebenaufgabe im Fahrzeug vermutlich weniger freie Kapazitäten verfügbar. Zusätzliche Schwankungen der Aufmerksamkeit, repräsentiert durch Alpha-Spindeln, haben deshalb, im Vergleich zum Labor, eine stärkere Auswirkung auf die Reaktionszeit.

Das Auftreten einer Alpha-Spindel führt, wie in der Hypothese angenommen, zu einer verbesserten Detektionsrate akustischer Stimuli. Dieser Effekt ist im Ver-

gleich zu den vorgestellten Studien ebenfalls relativ schwach ausgeprägt. Grund hierfür ist vor allem die sehr einfache Detektionsaufgabe, wodurch Aufmerksamkeitsschwankungen nur geringe Auswirkungen auf die Detektionsleistung haben. Die ausgeprägten Effekte in den Studien von [Ergenoglu et al. \(2004\)](#), [Linkenkaer-Hansen et al. \(2004\)](#), [van Dijk et al. \(2008\)](#) und [Mathewson et al. \(2009\)](#) lassen sich auf die wesentlich schwierigere Detektionsaufgabe zurückführen, da Stimuli an der Wahrnehmungsschwelle verwendet werden, weshalb Schwankungen in der kognitiven Leistungsfähigkeit eine höhere Auswirkung auf die Detektionsrate haben.

Die Hypothese, dass der Einfluss einer Spindel auf die Reaktionszeit bei schwierigeren Reizen größer ist, konnte mit dem vorliegenden Experiment nicht bestätigt werden. Es wurde angenommen, dass seltene Töne schwieriger zu detektieren sind, was durch eine verlangsamte Reaktion von 56 ms im Labor bzw. 86 ms im Fahrzeug gegenüber häufigen Stimuli bestätigt wird. Die Auswirkung der Spindeln auf die Reaktionszeit ist für seltene Stimuli, entgegen der Hypothese, allerdings schwächer als für häufige Töne. Eine mögliche Erklärung hierfür ist der aktivierende Effekt eines unerwarteten Reizes, welcher die Einflüsse unterschiedlicher Aufmerksamkeit, repräsentiert durch Alpha-Spindeln, überlagert bzw. aufhebt. Experimentelle Paradigmen, welche die Schwierigkeit der Reizdiskrimination z.B. durch geringere Tonhöhenunterschiede realisieren, könnten die hier aufgestellte Hypothese bestätigen.

Die Hypothese, dass steigende kognitive Anforderungen in der Primäraufgabe den Effekt von Alpha-Spindeln auf die Reaktionszeit verstärken, kann bestätigt werden. Dies zeigt sich vor allem durch die bereits beschriebene intensivere Auswirkung der Koinzidenz während der Fahrt, da hier eine wesentlich höhere Beanspruchung durch die Primäraufgabe vorherrscht. Die Steigerung der Schwierigkeit in den experimentellen Bedingungen im Labor zeigt zwar eine Verlangsamung der Reaktion, allerdings gibt es keine signifikante Interaktion mit dem Faktor *Koinzidenz*. Im Labor ist also keine Verstärkung des Koinzidenzeffektes durch höhere Beanspruchung in der Primäraufgabe zu beobachten. Es ist anzunehmen, dass die Variation der Beanspruchung im Labor nicht ausreichend ist, um den hypothetisierten Interaktionseffekt hervorzurufen.

Die Verwendung gemischter Modelle für die vorgestellten Analysen bietet eine hohe ökologische Validität der Auswertung unter Berücksichtigung aller in den Daten enthaltenen Informationen. Da keine Mittelwerte für verschiedene Gruppierungsfaktoren über die Probanden gebildet werden müssen, geht die gesamte

Variation der Daten in die Analyse ein, was zu realistischen Ergebnissen führt. Auch die bei der Mittelung ansonsten wegfallende unterschiedliche Stichprobengröße für verschiedene Faktoren geht in die Analyse ein, was besonders für die Signifikanzprüfung der festen Effekte auf Grund der unterschiedlichen Standardfehler eine wichtige Rolle spielt. Die Analyse mittels gemischter Modelle ermöglicht eine realistische Abschätzung ob eine single-Trial Prädiktion von Reaktionszeiten mit Hilfe von Alpha-Spindeln erfolgreich sein würde. Das relativ hohe Residuum der linearen gemischten Modelle im Vergleich zu den ermittelten Effektgrößen macht aber deutlich, dass eine Messung des Koinzidenzeffektes nicht auf Basis einzelner Trials möglich ist, sondern nur durch wiederholte Messung des gleichen Zustandes statistisch erfasst werden kann. Die weiterführende Anwendung von Klassifikationsverfahren zur Prädiktion von Reaktionszeiten erscheint auf Basis der hier vorgestellten Ergebnisse nicht lohnenswert.

Kapitel 3

Klassifikation

In den Abschnitten 2.3.1 und 2.3.3 wird gezeigt, dass statistisch signifikante Zusammenhänge zwischen Alpha-Spindelmaßen (Spindelrate, -dauer und -amplitude) und aufgabenbezogener Müdigkeit bei Experimenten im realen Straßenverkehr bestehen. Demnach deuten in Experiment I (Abschnitt 2.3.1) mehrere unabhängige Indikatoren (Reaktionszeit, P300-Amplitude, Herzrate) auf eine Ermüdung der Probanden mit zunehmender Fahrdauer hin. Für die Spindelrate kann ein analoger Trend beobachtet werden. Die Analyse von Probanden, welche den Versuch wegen starker Ermüdung abbrechen (s. Abschnitt 2.3.3), zeigt signifikante Veränderungen der Spindelparameter beim Vergleich von Fahrtabsechnitten zu Beginn der Fahrt und unmittelbar vor dem Abbruch. Mit der Analyse der Abbrecher ist sichergestellt, dass ein objektives, sicherheitsrelevantes Kriterium für die Definition von Müdigkeit herangezogen wird. Vor dem Hintergrund, dass eine Selbsteinschätzung der eigenen Müdigkeit nicht immer verlässlich ist (s. 2.3.1), ist ein objektives Kriterium besonders wichtig.

Beide Ergebnisse motivieren die Anwendung von Klassifikationsverfahren zur Prädiktion verschiedener Müdigkeitsstadien. Signifikante Ergebnisse in Hypothesentests auf Gruppenebene lassen allerdings noch keine Rückschlüsse auf die prädiktiven Fähigkeiten von Klassifikatoren, insbesondere deren Generalisierbarkeit für unbekannte Daten bzw. Personen, zu. Denn Individuen können trotz signifikanter Ergebnisse für die Population, starke individuelle Merkmalsausprägungen ausbilden und damit schlechte Resultate bei einer Prädiktion erzielen. Deshalb werden in diesem Kapitel verschiedene Klassifikationsansätze und Merkmalsgruppen auf der Basis möglichst objektiver Müdigkeitsreferenzen untersucht.

Literaturrecherche

In der Literatur existiert eine Vielzahl unterschiedlichster Ansätze zur Klassifikation von Müdigkeit anhand neurophysiologischer Daten. Die nachfolgende Übersicht erhebt keinen Anspruch auf Vollständigkeit, sondern will verschiedene Konzepte vorstellen und deren Relevanz für die vorliegende Aufgabenstellung prüfen.

In einer Studie von (Shen et al., 2008) werden EEG-Merkmale verwendet, die den hier verwendeten Alpha-Spindeln ähnlich sind. Es wird die dominante Frequenz in den vier klassischen EEG-Frequenzbändern (δ , θ , α und β) extrahiert und anhand mehrerer spektraler Eigenschaften charakterisiert. Auf Basis der Performance in einer auditorischen Primäraufgabe werden fünf individuelle Klassen definiert. Mittels einer probabilistischen Mehrklassen-SVM können mit einem probandenunabhängigen Klassifikatormodell sehr gute Ergebnisse erzielt werden (mittlere TPR: 91,2%), wobei vor allem die Extremzustände 1 (sehr gute Performance) und 5 (sehr schlechte Performance) sehr gut trennbar sind.

Den Ansatz unterschiedliche Performancemaße aus einer Primäraufgabe als Referenz für das Klassifikatortraining zu verwenden, verfolgen auch andere Studien (z.B. Jung et al., 1996; John et al., 2006), wobei unklar bleibt inwieweit die gewählten Performancemaße tatsächlich Müdigkeit im Fahrkontext repräsentieren. Naheliegender sind hier Performancemaße direkt aus dem Fahrverhalten, wie z.B. die Standardabweichung der lateralen Position innerhalb einer Spur (SDLP), welche bei Liang et al. (2005) und Pal et al. (2008) verwendet wird. Beide Studien können mit EEG-Bandleistungsmerkmalen signifikante Korrelationen zwischen der Klassifikatorscore und dem Performancemaß erzielen. Der Zusammenhang zwischen tatsächlicher Ermüdung der Probanden und den verwendeten Performancemaßen wird allerdings in keiner der Studien erbracht, wodurch andere Einflüsse für Leistungseinbrüche nicht auszuschließen sind.

Ein alternativer Ansatz, um zu einer Müdigkeitsreferenz zu gelangen, besteht darin Experten den Verlauf des Experiments in diskrete Vigilanzlevel einteilen zu lassen. In den Studien von Davidson et al. (2007) und King et al. (2006) werden Videoaufnahmen vom Gesicht des Fahrers durch Experten in zwei diskrete Stufen unterteilt. Kritisch zu bewerten ist dabei der Ansatz von Davidson et al. (2007), bei dem Sekundenschlaf (lapses) durch geschlossene Augen identifiziert wird und anschließend Bandleistungsmerkmale zur Klassifikation dieser Ereignisse herangezogen werden. Es ist bekannt, dass insbesondere das Alpha-Band sehr stark auf

das Schließen der Augen reagiert, unabhängig vom Vigilanzzustand, sodass der Klassifikator eventuell nur das Schließen der Augen, nicht aber Sekundenschlaf erkennen kann. Andere Studien lassen Experten EEG- und EOG-Aufzeichnungen in zwei (Vuckovic et al., 2002; Picot et al., 2008; Yeo et al., 2009) bzw. drei (Subasi et al., 2005) Müdigkeitsstadien einteilen. Problematisch ist hier, dass im Anschluss wiederum EEG-Daten verwendet werden, um dieses Expertenrating zu präzisieren. Eine externe und unabhängige Müdigkeitsreferenz ist damit nicht gegeben.

In den Studien von Hu und Zheng (2009) und Sommer et al. (2009) werden Selbsteinschätzungen der Probanden (Karolinska Sleepiness Scale) als Müdigkeitsreferenz herangezogen. Die 9-stufige Skala wird in zwei bzw. drei Stufen zusammengefasst. Beide Studien verwenden Support-Vektor-Maschinen als Klassifikatoren und erzielen einen Klassifikationsfehler von 13% für zwei Klassen (Sommer et al., 2009) bzw. 80% Genauigkeit für drei Klassen (Hu und Zheng, 2009).

Trejo et al. (2005) und Liu et al. (2010) verwenden Daten zweier unterschiedlicher Abschnitte eines Vigilanzexperimentes, welche einerseits ein wacher Zustand zu Beginn des Experimentes und andererseits ein ermüdeter Zustand am Ende des Experimentes oder unmittelbar danach entsprechen. Trejo und Kollegen können, mit Hilfe von auf den Probanden adaptierten Kernel Partial Least Squares und Bandleistungsmerkmalen, im Mittel 97% Klassifikationsgenauigkeit erzielen. Liu und Kollegen verwenden eine EEG-Referenzmessung vor bzw. nach dem eigentlichen Experiment und können diese Abschnitte, mit Hilfe von Hidden Markov Modellen und Komplexitätsmaßen aus dem EEG, mit einer Sensitivität von 90% präzisieren. Da die Referenzabschnitte zur Klassifikation nicht während des eigentlichen Versuchs aufgezeichnet werden, ist unklar wie stark die Ausübung der Vigilanzaufgabe die Klassifikationsperformance beeinflussen würde, wenn eine Klassifikation des Vigilanzlevels während der eigentlichen Aufgabe durchgeführt würde.

Eine Sonderstellung nimmt der Ansatz von Johnson et al. (2011) ein. Hier wird postuliert, dass EEG-Muster, welche bei der Ausübung drei verschiedener Baselineaufgaben entstehen, bestimmten Vigilanzzuständen entsprechen (hohe Aufmerksamkeit, geringe Aufmerksamkeit, Ablenkung). Der vierte Zustand, welcher in der Baseline nicht erzeugt werden kann (Sleep Onset) wird aus einer Stichprobe eines Schlafdeprivationsexperimentes extrapoliert. Nach Ausübung der Baseline unterscheidet das Verfahren mittels einer quadratischen Diskriminanzanalyse zwischen vier Vigilanzzuständen in 1s Intervallen in Echtzeit. Die Validität des Klassifikators wird in klinischen Studien überprüft und kommt zu brauchbaren

Resultaten. Eine vergleichbare Performance kann allerdings bei Experimenten im realen Straßenverkehr nicht erzielt werden.

Die vielen verschiedenen Ansätze hinsichtlich einer Referenz für Müdigkeit sowie des experimentellen Paradigmas zeigen wie schwierig es ist eine objektive und valide Definition von Müdigkeit zu entwickeln. Die weitläufigen Interpretationsmöglichkeiten führen zu sehr unterschiedlichen Ansätzen. Aus diesem Grund sind die Ergebnisse der vorgestellten Studien kaum vergleichbar, da die gewählten Referenzen sowie die zu Grunde liegenden Experimente zu verschieden sind. Bis auf [Johnson et al. \(2011\)](#) hat keine der Studien Versuche in realitätsnahen Situationen im Fahrkontext, ähnlich der vorliegenden Arbeit, durchgeführt. Durch die Zunahme von unkontrollierbaren Störeinflüssen bei solchen Experimenten ist anzunehmen, dass die Klassifikationsergebnisse aus Laborexperimenten dadurch negativ beeinflusst werden. Ergebnisse der geschilderten methodischen Ansätze zur Klassifikation von Müdigkeit bedürfen also unbedingt einer Überprüfung, einerseits hinsichtlich deren Validität in Experimenten im realen Straßenverkehr und andererseits in Bezug auf die gewählte Referenz für Müdigkeit.

Im Folgenden werden zwei verschiedene Ansätze zur Klassifikation von Müdigkeit untersucht, die sich hauptsächlich durch die gewählte Müdigkeitsreferenz und die zu Grunde liegende Stichprobe unterscheiden. Die Wahl eines geeigneten Klassifikators für den jeweiligen Ansatz richtet sich nach der entsprechenden Struktur der Daten und der gewünschten Zielgröße (diskrete Klassenzuordnung, Bestimmung der a-posteriori Wahrscheinlichkeit). Wie bereits in Abschnitt 2.3.3 angestrebt, werden möglichst objektive, fahrrelevante Müdigkeitsreferenzen verwendet. Die einzelnen Ansätze sind in den jeweiligen Unterkapiteln näher erläutert.

Ziel ist die Entwicklung eines probandenunabhängigen Klassifikationsmodells, d.h. der auf Basis der erhobenen Daten trainierte Algorithmus kann auch auf neue, unbekannte Probanden in Folgeexperimenten angewendet werden. Diese Zielsetzung ergibt sich aus der Forderung nach einem echtzeitfähigen Klassifikator. Das Training probandenspezifischer Klassifikatoren würde Daten des jeweiligen Versuchsteilnehmers im ermüdeten Zustand erfordern. Diese können nur durch eine separate Trainingssession, in welcher der Proband im Laufe des Experimentes ermüdet, ergänzt um eine Testsession an einem Folgetag, erhoben werden. Ein solches Experimentdesign erfordert für jeden Probanden zwei Fahrten mit einer Fahrdauer von je 2 bis 4 Stunden. Damit ist eine Erhebung für eine aussagekräftige Stichprobengröße (ausreichend Probandenanzahl) in einem akzeptablen

zeitlichen Rahmen nicht realisierbar. Da individuelle Unterschiede in der Ausprägung der physiologischen Merkmale hinsichtlich Müdigkeit aus der Literatur und eigenen Untersuchungen bekannt sind (s. Abbildung 2.14), ist zu erwarten, dass ein probandenunabhängiger Klassifikator gegenüber einem individualisierten Modell geringere Trennschärfe besitzt. Für die Entwicklung praktisch anwendbarer Algorithmen wird dieser Nachteil allerdings in Kauf genommen. Es sei darauf hingewiesen, dass für die Realisierung eines probandenunabhängigen Klassifikatormodells die erfolgreiche Klassifikation von Müdigkeit mit individualisierten Modellen eine notwendige Voraussetzung ist. Im Rahmen einer Bachelorarbeit bei der Daimler AG wurde dies überprüft (Tarajan, 2009). Mit Hilfe eines linearen Klassifikators und Merkmalen der Spindelaktivität sind hier wache Fahrtabschnitte zu Beginn der Fahrt von Segmenten kurz vor Abbruch der Fahrt sehr gut trennbar.

3.1 Klassifikation der Abbrecher

Der folgende Abschnitt knüpft an die Analyse aus Kapitel 2.3.3 an. Dort wird argumentiert, dass der Abbruch einiger Teilnehmer auf Grund starker Ermüdung als objektive Referenz für Müdigkeit angesehen werden kann und die Analyse deshalb auf diese 10 Abbrecher beschränkt wird. Insbesondere kann anhand von Beobachtungen des Versuchsleiters während der Fahrt, Videoauswertungen des Fahrers und der Selbsteinschätzung des Probanden (vor dem Abbruch: KSS im Mittel 8,5) eine Phase unmittelbar vor dem Abbruch identifiziert werden, in der der Proband starke Anzeichen von Müdigkeit zeigt. Dieser Fahrabschnitt von 20 min dient als objektive Referenz für Müdigkeit. Als Wachphase werden die ersten 20 min der Fahrt angesetzt. Da die Fahrt gegen 13 Uhr beginnt und die Probanden eine KSS von 4 zu Beginn angeben, ist es plausibel anzunehmen, dass in einem kurzen Abschnitt zu Beginn der Fahrt noch keine nennenswerte Müdigkeit auftritt und dieser Abschnitt als Referenz für den wachen Zustand dienen kann. Die Analyse beschränkt sich also auf ein 2-Klassenproblem, wobei eine Wachphase einer Autofahrt von einer Phase starker Ermüdung getrennt werden soll. Mangels einer verlässlichen Referenz für die dazwischen liegenden Daten, werden diese Abschnitte für die Entwicklung eines Klassifikatormodells vorerst nicht in Betracht gezogen.

Merkmale

Zur Klassifikation werden neben den bekannten Spindelmerkmalen (Spindelrate, -dauer und -amplitude), welche in drei Kanalgruppen gemittelt werden (s. Tabelle 2.2), auch Merkmale des Blinzelverhaltens genutzt, was einen Merkmalsvektor der Länge 14 ergibt. Aus der Literatur ist bekannt, dass Parameter des Augenblinzeln mit Vigilanzveränderungen korrelieren (Dinges et al., 1998; Caffier et al., 2003; Schleicher et al., 2008). Ein Klassifikator kann von komplementären Informationen aus beiden Merkmalsgruppen profitieren. Charakteristika des Blinzelverhaltens werden aus dem EOG, nach einer Methode von Caffier et al. (2003), extrahiert und beinhalten die folgenden Parameter:

- Blinzeldauer: FWHM-Breite des Blinzelpеaks (sec)
- Blinzelfrequenz: Blinzelhäufigkeit in einem Analysefenster (1/min)
- Blinzelamplitude: Amplitude des Blinzelpеaks (μV)
- PERCLOS80: Dauer, die das Lid zu mehr als 80% geschlossen ist (sec)
- Asymmetrie: Differenz der Öffnungs- zu Schließdauer des Lides (sec)

Alle o.g. Parameter werden, analog den Spindelmerkmalen, in einem gleitenden Fenster von 5 min Dauer und 50s Versatz gemittelt. Eine Analyse aus Kapitel 2.3.3 für die Spindelrate bzgl. der optimalen Fensterlänge für eine Diskrimination der 20 min-Abschnitte legt nahe 3 min bzw. 5 min Fenster zu verwenden, um einen guten Kompromiss zwischen Zeitauflösung und Trennschärfe zu erhalten (s. Abbildung 2.13). Pro Proband ergibt sich eine Stichprobengröße von 36 Samples, d.h. 360 Samples insgesamt.

Es wird auf die Nutzung detaillierter räumlicher Filter für die EEG-Merkmale bewusst verzichtet. Stattdessen werden drei statische Kanalgruppen verwendet (frontal, zentral, parieto-okzipital, s. Tabelle 2.2). Die Ergebnisse aus Abschnitt 2.3.3.2 zeigen, dass die Merkmale in allen Kanalgruppen signifikante Veränderungen durch Müdigkeit erfahren und somit für die gesamte Population kein ausgeprägter lokaler Effekt zu erwarten ist, was die Optimierung räumlicher Filter rechtfertigen würde. Für das Individuum sind allerdings lokale Effekte sichtbar (s. Abbildung 2.14), was vermuten lässt, dass personalisierte Klassifikatoren von einem spezifischen räumlichen Filter profitieren können.

Normierung

Um einen probandenunabhängigen Klassifikator zu entwickeln, müssen die Merkmale für jeden Probanden normiert werden, da zum Teil große interindividuelle Unterschiede im Mittelwert bzw. der Varianz bestehen (s. z.B. Abbildung 2.14). Für eine Anwendung des Klassifikators in Echtzeit können nicht die gesamten Daten der Messung für die Normierung herangezogen werden. Stattdessen werden in einer Kalibrationsphase zu Beginn des Experimentes die Normierungsparameter bestimmt und auf die darauf folgenden Daten angewendet. Im Weiteren werden die 1. 20 min (Wachphase) zur Normierung herangezogen. Verwendet wird die z-Transformation

$$X_{norm}(t) = \frac{X(t) - \mu_{wach}}{\sigma_{wach}}.$$

Um die Verhältnisse zwischen den Kanalgruppen zu erhalten, werden für die EEG-Merkmale μ_{wach} und σ_{wach} gepoolt über alle Kanalgruppen berechnet und anschließend auf jede Gruppe angewendet.

Kreuzvalidierung

Zur Bestimmung der Klassifikationsperformance wird ein Kreuzvalidierungsschema herangezogen, welches die Anwendung des Klassifikators in Echtzeit für unbekannte Probanden simuliert. Angelehnt an die Leave-one-out Kreuzvalidierung werden in einer Iteration alle Daten eines Probanden zum Test verwendet und die Daten der restlichen neun Probanden zum Training, was in 10 Kreuzvalidierungsschritten resultiert. Da die Daten eines Probanden korreliert sind, ist nur auf diese Weise sichergestellt, dass Trainings- und Testset voneinander unabhängig sind und eine echte Validierung bzgl. unbekannter Probanden stattfindet.

3.1.1 Diskriminanzanalyse

Als Klassifikatoren kommen einfache Diskriminanzfunktionen zum Einsatz. Die Resultate der Analysen aus Kapitel 2.3.3 deuten darauf hin, dass die Klassenunterschiede hauptsächlich im Mittelwert (durch Trends in den Daten) und den Kovarianzen liegen, was die Anwendung einer Diskriminanzanalyse nahelegt. Weiterhin ist anzunehmen, dass komplexere Klassifikatoren schnell zu einer Überanpassung, und damit zu einer schlechten Generalisierbarkeit führen, da die Stichprobengröße begrenzt ist und interindividuelle Unterschiede in den Merkmalsausprägungen

bekannt sind.

Lineare Diskriminanzfunktion

Das Ziel einer linearen Diskriminanzanalyse (LDA) besteht darin, eine lineare Transformation des $(n \times 1)$ -dimensionalen Merkmalsvektors \mathbf{x} zu finden, sodass die Klassenseparierbarkeit im transformierten Raum maximiert und damit der Klassifikationsfehler minimiert wird. Die lineare Diskriminanzfunktion $h(\mathbf{x})$ für das 2-Klassenproblem ist gegeben durch

$$h(\mathbf{x}) = \mathbf{w}'\mathbf{x} + w_0, \quad (3.1)$$

mit dem $(n \times 1)$ -dimensionalen Gewichtsvektor \mathbf{w}' (Fukunaga, 1990). Gilt für eine Beobachtung $h(\mathbf{x}) > 0$ oder $h(\mathbf{x}) \leq 0$, so wird diese Beobachtung der Klasse C_1 bzw. C_2 zugewiesen. Um die optimalen Gewichte $\mathbf{w} = [w_1 \dots w_n]'$ zu bestimmen, wird das *Fisher-Kriterium*

$$J(\mathbf{w}) = \frac{(m_2 - m_1)^2}{s_1^2 + s_2^2} \quad (3.2)$$

maximiert (Bishop, 2006). Dabei bezeichnet m_i den projizierten Erwartungswert $\boldsymbol{\mu}_i$ der Klasse C_i

$$m_i = \mathbf{w}'\boldsymbol{\mu}_i$$

und s_i^2 ist die entsprechende Projektion der Kovarianz Σ_i

$$s_i^2 = \mathbf{w}'\Sigma_i\mathbf{w}.$$

Das Fisher-Kriterium ist also das Verhältnis von Interklassenvarianz zu Intraklassenvarianz, welches maximal sein soll. Die Maximierung von 3.2 führt zu

$$\mathbf{w} = \left[\frac{1}{2}\Sigma_1 + \frac{1}{2}\Sigma_2 \right]^{-1} (\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1) \quad (3.3)$$

als optimalem Gewichtsvektor (Fukunaga, 1990). Die Entscheidungsgrenze (z.B. $h(\mathbf{x}) = 0$) ist linear, d.h. eine Hyperebene im n -dimensionalen Merkmalsraum. Für normalverteilte Merkmale und gleiche a-priori Wahrscheinlichkeiten für beide

Klassen ergibt sich die Konstante w_0 zu

$$\begin{aligned} w_0 &= -\mathbf{w}'(\boldsymbol{\mu}_2 + \boldsymbol{\mu}_1) \\ &= \frac{1}{2}(\boldsymbol{\mu}'_1 \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_1 - \boldsymbol{\mu}'_2 \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_2), \end{aligned} \quad (3.4)$$

mit $\boldsymbol{\Sigma} = 1/2(\boldsymbol{\Sigma}_1 + \boldsymbol{\Sigma}_2)$ (Fukunaga, 1990).

Die Diskriminanzfunktion $h(\mathbf{x})$ ist proportional zur vorzeichenbehafteten Distanz von \mathbf{x} zur Hyperebene. Die exakte Entfernung r von \mathbf{x} zur Hyperebene ist gegeben durch (Bishop, 2006)

$$r = \frac{h(\mathbf{x})}{\|\mathbf{w}\|}.$$

Die lineare Diskriminanzfunktion ist nur dann optimal, wenn die Kovarianzmatrizen $\boldsymbol{\Sigma}_1$ und $\boldsymbol{\Sigma}_2$ identisch sind. Für den Fall $\boldsymbol{\Sigma}_1 \neq \boldsymbol{\Sigma}_2$ wird die sog. quadratische Diskriminanzfunktion benötigt.

Quadratische Diskriminanzfunktion

Für den Fall $\boldsymbol{\Sigma}_1 \neq \boldsymbol{\Sigma}_2$ kann ein quadratischer Klassifikator mit der Diskriminanzfunktion (QDA)

$$h(\mathbf{x}) = \mathbf{x}'Q\mathbf{x} + \mathbf{w}'\mathbf{x} + w_0 \quad (3.5)$$

verwendet werden, wobei Q eine symmetrische, quadratische Matrix der Dimension $(n \times n)$ ist (Fukunaga, 1990). Gleichung 3.5 kann durch Umformung auch als eine lineare Gleichung aufgefasst werden:

$$\begin{aligned} h(\mathbf{x}) &= \sum_{i=1}^n \sum_{j=1}^n q_{ij} x_i x_j + \sum_{i=1}^n w_i x_i + w_0 \\ &= \sum_{i=1}^{\frac{n(n+1)}{2}} \alpha_i y_i + \sum_{i=1}^n w_i x_i + w_0, \end{aligned} \quad (3.6)$$

wobei q_{ij} und w_i die Komponenten von Q und \mathbf{w} sind. y_i repräsentiert das Produkt aus zwei x -Variablen und α_i ist das entsprechende Gewicht einer linearen Transformation. Die Optimierung von 3.6 kann nun nach dem gleichen Schema wie für die lineare Diskriminanzfunktion erfolgen, was in der Lösung

$$\left[\alpha_1, \dots, \alpha_{\frac{n(n+1)}{2}}, w_1, \dots, w_n \right]' = \left[\frac{1}{2}K_1 + \frac{1}{2}K_2 \right]^{-1} (D_2 - D_1) \quad (3.7)$$

resultiert (Fukunaga, 1990). D_i ist der Vektor der Erwartungswerte und K_i die Kovarianzmatrix von $z = [y', x']'$. w_0 bestimmt sich damit zu

$$w_0 = \frac{1}{2}(\boldsymbol{\mu}'_1 \Sigma_1^{-1} \boldsymbol{\mu}_1 - \boldsymbol{\mu}'_2 \Sigma_2^{-1} \boldsymbol{\mu}_2 + \ln |\Sigma_1| - \log |\Sigma_2|).$$

Die resultierende Entscheidungsgrenze kann die Form von Hyperellipsoiden, Hyperkugeln oder Hyperebenen annehmen. Die LDA ist somit ein Spezialfall der QDA, jedoch hat die QDA $n(n+1)/2$ zusätzliche Freiheitsgrade, da zwei Kovarianzmatrizen (anstatt einer für die LDA) bestimmt werden müssen. Bei kleinem Stichprobenumfang (relativ zur Anzahl der Merkmale), kann die LDA deshalb robuster gegen Überanpassung sein und darum, trotz Daten mit ungleichen Kovarianzen, bessere Klassifikationsergebnisse erzielen.

3.1.2 Ergebnisse

Die Performance der probandenunabhängigen Klassifikatoren wird anhand von ROC-Kurven und AUC-Werten verglichen. Dazu werden die Prädiktionen des Klassifikators aus jedem Kreuzvalidierungsschritt aggregiert und eine ROC-Kurve ermittelt. Abbildung 3.1 zeigt die Ergebnisse für LDA und QDA sowie die zugehörigen AUC-Werte. Beide Klassifikatoren ermöglichen die Diskrimination der 20 min Abschnitte, wobei die QDA eine deutlich bessere Performance im Vergleich zur LDA erzielt. Mit Hilfe eines nichtparametrischen Tests werden die statistischen Unterschiede zwischen den AUC-Werten beider Klassifikatoren untersucht (DeLongs Test für korrelierte ROC-Kurven, DeLong et al. (1988)). Die QDA hat mit 0,959 einen signifikant höheren AUC-Wert als die LDA mit 0,855 ($Z = -5,502$, $p < 0,001$).

Um zu prüfen, ob die gewählte Normierung effektiv ist, wird auch eine ROC-Analyse für unnormierte Daten durchgeführt. Dies führt zu deutlich geringeren AUC-Werten von 0,56 für die QDA und 0,77 für die LDA. Wie bereits postuliert, ist eine Normierung von größter Wichtigkeit, um interindividuelle Unterschiede zu reduzieren.

Die gewählte Dauer der Referenzabschnitte ist eine auf Erfahrungswerten der Versuchleiter basierte Entscheidung. Es wird deshalb untersucht wie stark die Performance der Klassifikatoren von der Länge der Referenzabschnitte abhängt bzw. ob 20 min die optimale Wahl ist. Dazu werden Referenzabschnitte von 10, 15, 20, 25 und 27,5 min gewählt. Die Bestimmung der Normierungsparameter wird

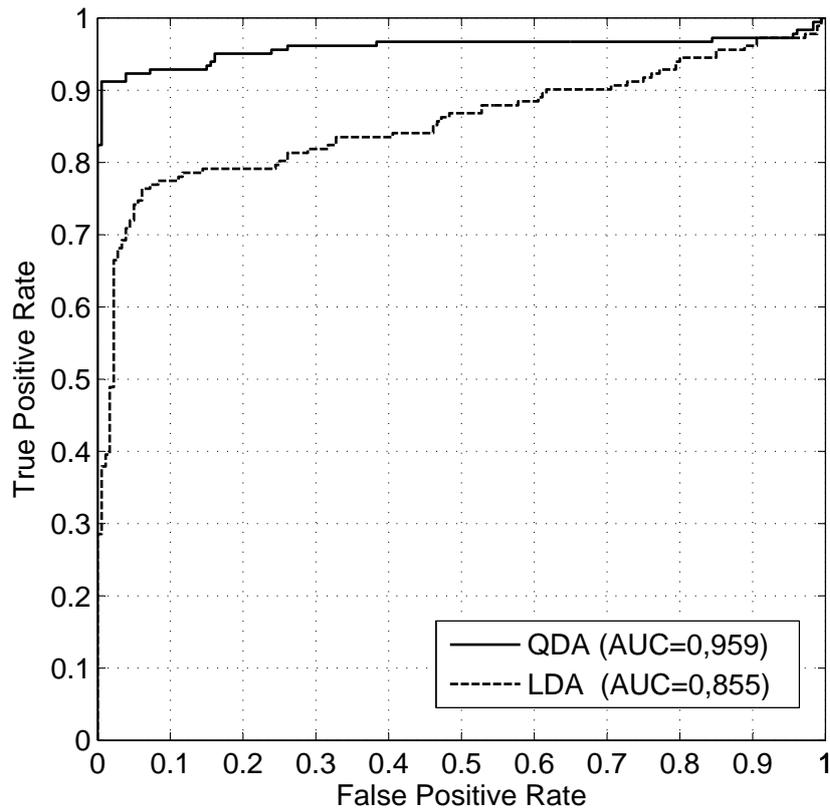


Abbildung 3.1: ROC-Kurven der ersten vs. letzten 20 min Fahrt der Abbrecher mit einer linearen (LDA) bzw. quadratischen (QDA) Diskriminanzanalyse.

jeweils im ersten Abschnitt vorgenommen. Für jede Aufteilung wird ein AUC-Wert mit einer QDA ermittelt und benachbarte Fensterlängen (z.B. 10 min vs. 15 min) werden mit einer adaptierten Version des Tests von DeLong aus dem **R**-Packet **pROC** (Robin et al., 2011) verglichen. Die Ergebnisse sind im oberen Teil der Abbildung 3.2 dargestellt. Die AUC-Werte nehmen von 10 min bis 25 min zu und fallen für 27,5 min wieder stark ab. Die höchsten AUC-Werte werden also für 25 min erzielt, wobei kein signifikanter Unterschied zu einer Fensterlänge von 20 min besteht ($p = 0,189$).

Da eine kontinuierliche Referenz für Müdigkeit nicht vorliegt, können auf diese Weise nur Abschnitte zu Beginn und am Ende der Fahrt analysiert werden. Das Verhalten des Klassifikators für die dazwischen liegenden Daten, wenn auch relevant, kann auf diese Art nicht untersucht werden. Der Verlauf der Diskriminanzwerte für diese Daten ist allerdings wichtig für die Plausibilisierung des Ansatzes. Erwartet wird ein allmählicher, nicht zwingend monotoner Übergang

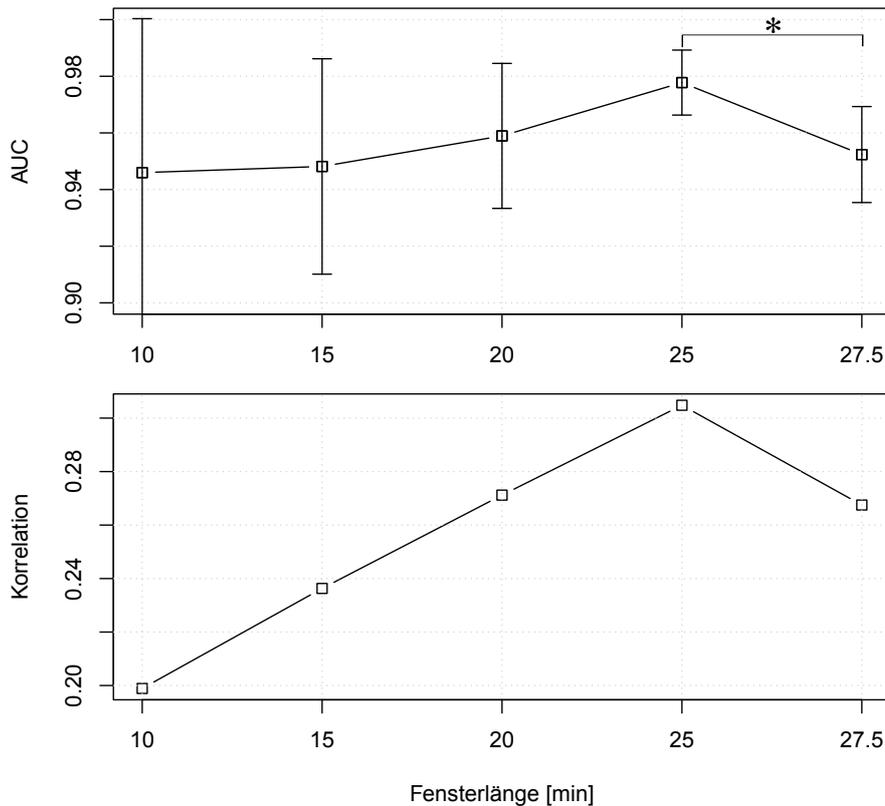


Abbildung 3.2: Oben: AUC-Werte und 95%-Konfidenzintervalle für verschiedene Längen der Referenzabschnitte. Sign. Unterschiede zwischen benachbarten AUC-Werten sind markiert (* $p < 0,05$). Unten: Mittlere Korrelationskoeffizienten zwischen Reaktionszeiten und Diskriminanzwerten.

zwischen den beiden gelabelten Abschnitten. Unplausibel ist z.B. ein Sprung der Diskriminanzwerte nach den ersten 20 min auf ein Niveau der letzten 20 min. Um die Klassifikationsergebnisse für diese Abschnitte trotzdem quantitativ beschreiben zu können, wird ein Vergleich mit einer unabhängigen Referenz herangezogen. Aus vorangegangenen Studien (Schmidt et al., 2009) ist bekannt, dass die Reaktionszeit auf einen auditorischen Oddball in einer Zweitaufgabe mit steigender Müdigkeit zunimmt (eine detaillierte Erläuterung der Zweitaufgabe findet sich in Abschnitt 2.4.1). Um einen Vergleich mit den Diskriminanzwerten zu ermöglichen, werden die Reaktionszeiten, analog den EEG- und EOG-Merkmalen, in einem gleiten Fenster von 5 min Länge gemittelt. Anschließend wird für jeden Probanden der Pearson-Korrelationskoeffizient zwischen Reaktionszeiten und Diskriminanzwerten berechnet. Um den mittleren Korrelationskoeffizienten aller Probanden zu erhalten, wird ein Verfahren nach Fisher (1954) angewendet, bei dem alle Koef-

fizienten mit der Fisher-Transformation in approximativ normalverteilte Größen umgewandelt, danach gemittelt und schließlich rücktransformiert werden. Eine genaue Beschreibung des Verfahrens ist in Abschnitt 2.3.4 zu finden. Der untere Teil von Abbildung 3.2 zeigt die mittleren Korrelationskoeffizienten für verschiedene Längen der Referenzabschnitte. Für alle Fensterlängen ist, konform zur Hypothese, eine positive Korrelation zu beobachten, mit einem Maximum für 25 min lange Abschnitte. Zu bemerken sei hier, dass 25 min Fensterlänge sowohl maximale Korrelation als auch Klassifikationsperformance erzielt. In Abbildung 3.3 sind die Korrelationskoeffizienten der einzelnen Probanden aufgetragen. Zu erkennen ist, dass sich die Probanden in eine Gruppe mit hoher Korrelation und eine mit nahezu keiner Korrelation aufteilen.

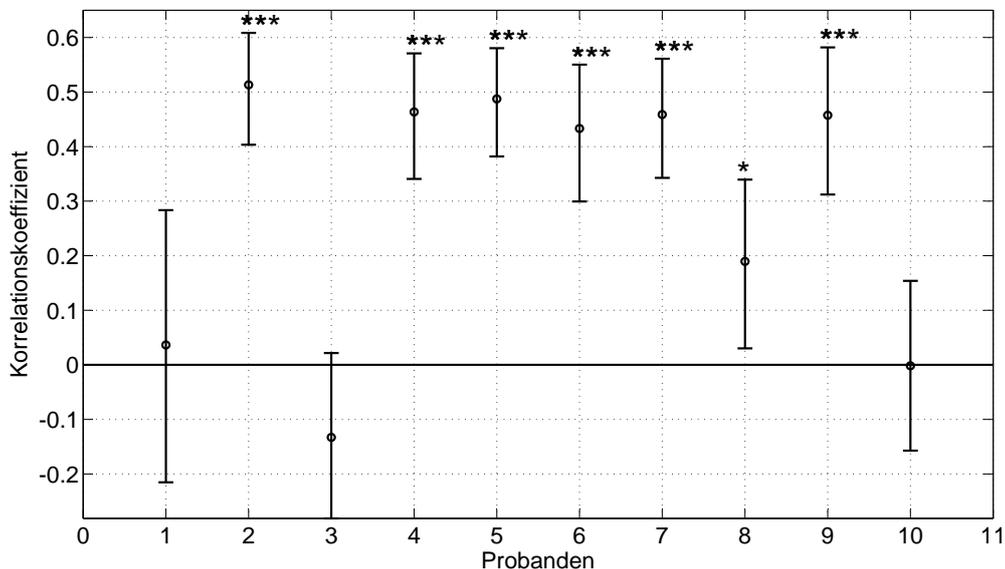


Abbildung 3.3: Korrelation der Diskriminanzwerte $h(x)$ der QDA mit der Moving Average Reaktionszeit aus dem auditorischen Oddball (* $p < 0,05$, *** $p < 0,001$). Für das Training werden 25 min Abschnitte zu Beginn und Ende der Fahrt verwendet. Je Proband werden jeweils die Kreuzvalidierungssamples zur Korrelation herangezogen.

Zur Veranschaulichung der Ergebnisse sind in Abbildung 3.4 einige Beispiele des Verlaufs von Diskriminanzwerten dargestellt. Deutlich sichtbar ist der allmähliche Anstieg der Diskriminanzwerte, was der Transition des Probanden vom wachen in den ermüdeten Zustand entspricht. Zu sehen sind weiterhin Peaks vor dem gelabelten müde-Abschnitt, welche Phasen hoher Ermüdung repräsentieren können. Laut Berichten der Probanden tritt besonders hohe Müdigkeit nicht nur unmittelbar vor dem Abbruch auf, sondern es gibt auch weiter zurück liegende Phasen ähn-

lich starker Ermüdung, von denen sich die Probanden wieder kurzfristig erholen können und erst deutlich später den Versuch abbrechen.

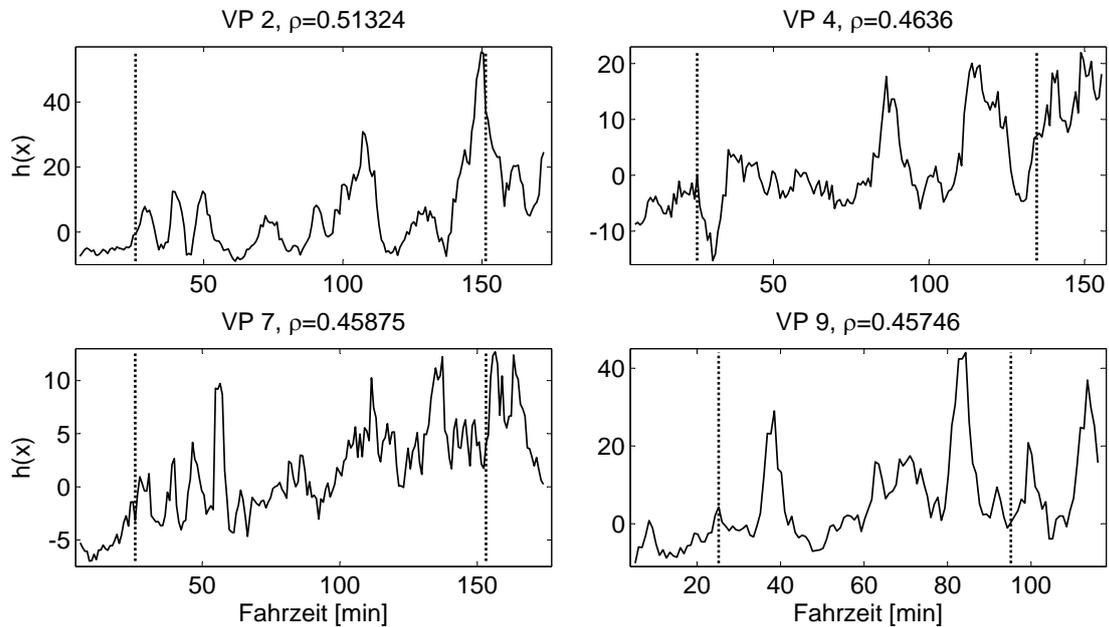


Abbildung 3.4: Beispiele für den Verlauf der Diskrimanzwerte $h(x)$ aus der QDA. Vertikale Linien markieren die Grenzen der gelabelten 25 min Abschnitte. Korrelationskoeffizienten ρ zwischen den Diskrimanzwerten und den Reaktionszeiten sind über jeder Grafik angegeben. Die fallenden Diskrimanzwerte bei VP7 und VP9 können durch Gespräche zwischen Versuchsleiter und Proband entstehen, nachdem entschieden wurde die Fahrt abzurechnen.

3.2 Prädiktion des Abbruchereignisses

Der vorherige Abschnitt legt dar, wie die Trennung von Fahrtabschnitten, in denen der Proband wach ist, von solchen, in denen er stark ermüdet und die Fahrt schließlich abbricht, mit einem probandenunabhängigen Klassifikator realisiert werden kann. Die Beschränkung auf Probanden, welche die Fahrt infolge starker Ermüdung abbrechen, liefert zwar eine objektive Referenz für Müdigkeit, allerdings können so große Teile der erhobenen Daten für die Analysen nicht berücksichtigt werden. Dies sind einerseits die Daten der Abbrecher, welche zwischen den Referenzabschnitten von 20 min Dauer liegen und ebenfalls wichtige Informationen über den Fahrerzustand enthalten, und andererseits sämtliche physiologischen Daten der Nicht-Abbrecher. Gerade die Daten der Nicht-Abbrecher sind jedoch für eine umfassende Bewertung eines Klassifikationsansatzes wichtig, um insbesondere Falschklassifikationen, d.h. Klassifizierung eines Datensegmentes als müde, obwohl keine Ermüdung vorliegt, für die gesamte Population quantifizieren zu können. Es ist nicht auszuschließen, dass die Beschränkung auf die Abbrecher im vorherigen Abschnitt einen Selektionsbias in der reduzierten Stichprobe beinhaltet, was zu optimistischen Klassifikationsergebnissen führen kann, insbesondere in Bezug auf die falsch-positiv-Rate (FPR).

Der folgende Abschnitt untersucht einen Ansatz, bei dem vollständige Fahrten der Abbrecher und Nicht-Abbrecher Berücksichtigung bei der Erstellung und Analyse eines probandenunabhängigen Klassifikators hinsichtlich Müdigkeit finden. Eine Einteilung in wach/müde-Segmente wie im vorherigen Abschnitt ist nun nicht mehr für jeden Datensatz möglich. Einziges objektives Unterscheidungskriterium bleibt weiterhin das Abbruchereignis einiger Probanden. Ein längerer Abschnitt vor dem Abbruch kann nicht als Referenz herangezogen werden, da unklar ist, inwieweit ein vergleichbares Müdigkeitslevel auch bei Probanden, die nicht abbrechen, auftritt, denn aus vorangegangenen Untersuchungen (s. Abschnitt 2.3.1 bzw. [Schmidt et al., 2009](#)) ist bekannt, dass auch bei Probanden, welche die volle Fahrstrecke absolvieren, eine zumindest zwischenzeitliche Ermüdung auftritt. Stattdessen wird im Folgenden der Ansatz verfolgt nur das Abbruchereignis selbst und ein unmittelbar zugehöriges Datensegment von 5 min Dauer von den restlichen Daten aller Probanden zu trennen, da der Abbruch als einziges objektives Unterscheidungskriterium bei Betrachtung der gesamten Stichprobe zur Verfügung steht. Die Ergebnisse aus Abschnitt 2.3.3.2 geben erste Hinweise darauf,

dass systematische Unterschiede zwischen Abbrechern und Nicht-Abbrechern bestehen. Insbesondere ist die signifikante Interaktion zwischen Fahrtabschnitt und den beiden Probandengruppen bedeutsam, da hier ein stärkerer Anstieg der Spindelmerkmale für die Abbrecher zu beobachten ist. Abbildung 2.12 zeigt zwar absolute Unterschiede zwischen beiden Probandengruppen, die durch die Normierung jedes Datensatzes allerdings wegfallen, sodass nur noch die stärkere Zunahme von Spindelrate, -amplitude und -dauer der Abbrecher für die Klassifikation relevant sein kann.

Ziel der Analyse ist die Wahrscheinlichkeit eines unmittelbar bevorstehenden Fahrtabbruchs (2-Klassenproblem) auf Basis von EEG- und EOG-Daten vorherzusagen. Um eine echte Vorhersage zu realisieren, werden Merkmale zum Zeitpunkt $t - 1$ verwendet, um einen Abbruch zum Zeitpunkt t zu präzisieren (s. Abbildung 3.5). Dazu werden die EEG- und EOG-Daten in nicht-überlappenden, gleitenden Mittelwertfenstern von 5 min Dauer berechnet und relativ zum Labelvektor um eine Zeiteinheit verzögert. Es besteht also die Aufgabe die Wahrscheinlichkeit eines Abbruchs innerhalb der nächsten 5 min zu ermitteln.

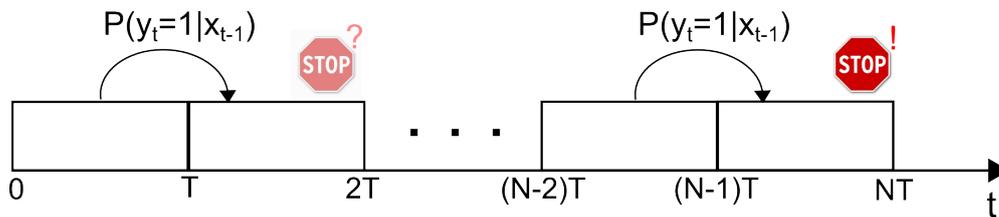


Abbildung 3.5: Schema der Vorhersage der Wahrscheinlichkeit P des Abbruchereignisses A_t zum Zeitpunkt t mit Hilfe des Merkmalsvektors \mathbf{x}_{t-1} zum Zeitpunkt $t - 1$. T ist die Fensterlänge von 5 min des gleitenden Mittelwertes und N die Stichprobengröße dieses Probanden.

Als zusätzliches Merkmal wird für diese Analyse die Fahrtzeit t hinzugenommen, sodass insgesamt 15 Merkmale zur Verfügung stehen. Als Klassifikator wird eine logistische Regression genutzt, da hiermit die a-posteriori Wahrscheinlichkeit für einen Abbruch $P(y_i = 1|\mathbf{x}_i)$ direkt modelliert werden kann. Das Einfügen der Zeit in ein logistisches Regressionsmodell ist eine geläufige Methode, um eine zeitabhängige Eintrittswahrscheinlichkeit des untersuchten Ereignisses, welche für die gesamte Population gilt, zu modellieren. Dieses Vorgehen ist eng verwandt mit der Lebensdauer- und Ereignisanalyse (Survival Analysis) und der hier häufig verwendeten Cox-Regression (Cox proportional hazards model, Beck et al., 1998). In der

Cox-Regression findet ebenfalls die Modellierung einer sog. Baseline-Hazardrate statt, welche die zeitabhängige Eintrittswahrscheinlichkeit des untersuchten Ereignisses, unabhängig von allen Merkmalen darstellt. Beispielsweise steigt für die Population bei der Untersuchung einer schweren Erkrankung mit der Beobachtungszeit das Risiko an dieser Krankheit zu sterben und dies geschieht unabhängig von weiteren Einflussgrößen. Diese Tatsache wird mit der Baseline-Hazardrate abgebildet. Cox-Modelle sowie deren Analogon, die logistische Regression mit einer Zeitvariable, sind weit verbreitet in der Analyse von Sterbewahrscheinlichkeiten (Hosmer und Lemeshow, 1998), Kreditrisikoanalysen (Löffler und Maurer, 2011) oder der Modellierung von Ausfallwahrscheinlichkeiten von Maschinen. Im Kontext des Autofahrens wird angenommen, dass Müdigkeit mit der Fahrtdauer zunimmt, sodass, für die Population die Wahrscheinlichkeit für einen Abbruch mit zunehmender Fahrtdauer ansteigt. Die individuellen Abweichungen von der Baseline-Hazardrate werden durch die Ausprägungen der restlichen zeitvariablen Prädiktoren des Modells bestimmt. Für eine Person, die bereits stark ermüdet einsteigt und nach sehr kurzer Zeit abbricht, würde das Risiko einer hohen Müdigkeit, welche schließlich zum Abbruch führt, mit geschildertem Modell unterschätzt werden. Dies stellt jedoch einen Ausnahmefall dar. Andererseits führt das Einfügen der Fahrtdauer in das Modell zu einer Stabilisierung der Prädiktionen, da implizit eine zeitabhängige Gewichtung der übrigen physiologischen Merkmale stattfindet, welche die Baseline-Abbruchrate der untersuchten Stichprobe widerspiegelt und ohne Vorkenntnisse über das Individuum die beste Schätzung für den Verlauf der Abbruchwahrscheinlichkeit darstellt.

Beim Vergleich der Abbrecher und Nicht-Abbrecher in Abschnitt 2.3.3.2 wird argumentiert, dass time-on-task, neben Müdigkeit, ebenfalls einen Einfluss auf die analysierten Merkmale hat. Deshalb wird die Fahrtdauer der Nicht-Abbrecher auf eine vergleichbare Länge wie die der Abbrecher verringert. Der gleiche Ansatz wird für nachfolgende Analysen aufgegriffen und erweitert. Anstatt eine zufällige Fahrtdauer je Proband zu wählen, werden 200 zufällige Ziehungen für jeden Datensatz durchgeführt. Mit jeder der 200 resultierenden Stichproben wird die Klassifikation des Abbruchereignisses vorgenommen. Kennwerte der Klassifikationsperformance (AUC, vorhergesagte Abbruchwahrscheinlichkeiten) werden über alle Stichproben gemittelt. Dieses Vorgehen ähnelt dem Bootstrapping-Ansatz, hat jedoch den Unterschied, dass die einzelnen Ziehungen auf Grund der abweichenden Fahrtdauern leicht unterschiedliche Daten enthalten können.

In den folgenden zwei Unterabschnitten werden die theoretischen Grundlagen

der logistischen Regression und ein Verfahren zur Regularisierung der Regressionskoeffizienten mit impliziter Merkmalsselektion (Lasso) erläutert.

3.2.1 Logistische Regression

Die logistische Regression stellt einen Spezialfall des generalisierten linearen Modells dar (s. Abschnitt 2.4.2.2), bei dem die Zielvariablen y_i einer Binomialverteilung folgen. Ziel ist die Bestimmung der a-posteriori Wahrscheinlichkeit π_i für das Eintreten von Ereignis $y_i = 1$, gegeben den Daten $\mathbf{x}_i = (1, x_{i1}, \dots, x_{ik})$ mit k Merkmalen. Der lineare Prädiktor $\mathbf{x}'_i\boldsymbol{\beta}$ wird über die Responsefunktion $h(x)$ in eine Wahrscheinlichkeit, d.h. das Intervall $[0, 1]$ überführt. Bei der logistischen Regression wird für $h(x)$ die logistische Verteilung (s. Abbildung 2.20) verwendet

$$\pi_i = P(y_i = 1|\mathbf{x}_i) = h(\mathbf{x}'_i\boldsymbol{\beta}) = \frac{e^{\mathbf{x}'_i\boldsymbol{\beta}}}{1 + e^{\mathbf{x}'_i\boldsymbol{\beta}}}, \quad (3.8)$$

wobei auch andere Responsefunktionen möglich sind (z.B. Probit, Fahrmeir et al., 2007). Da die Zielvariablen y_i binomialverteilt sind, ergibt sich die Likelihood-Funktion zu (Bishop, 2006)

$$L(\mathbf{y}|\boldsymbol{\beta}) = \prod_{i=1}^N \pi_i^{y_i} (1 - \pi_i)^{1-y_i}.$$

Logarithmieren von $L(\mathbf{y}|\boldsymbol{\beta})$ ergibt (Hastie et al., 2009)

$$\begin{aligned} \log L(\mathbf{y}|\boldsymbol{\beta}) &= \sum_{i=1}^N y_i \log \pi_i + (1 - y_i) \log(1 - \pi_i) \\ &= \sum_{i=1}^N y_i \mathbf{x}'_i\boldsymbol{\beta} - \log(1 + e^{\mathbf{x}'_i\boldsymbol{\beta}}). \end{aligned} \quad (3.9)$$

Die Maximierung von 3.9 kann iterativ über das Newton-Raphson Verfahren erfolgen. Die Gleichung für einen Iterationsschritt hat dabei die Form eines gewichteten kleinste Quadrate Schätzers, bei dem die Gewichtungsmatrix in jedem Iterationsschritt neu bestimmt wird (Hastie et al., 2009). Daraus leitet sich auch der Name des Verfahrens ab: *Iteratively Reweighted Least Squares* (IRLS).

3.2.2 L_1 -Regularisierung

Klassifikationsmodelle mit einer großen Anzahl an Merkmalen oder wenig Trainingsdaten generalisieren in der Regel schlecht, da schnell eine Überanpassung an das Trainingsset auftritt. Häufig werden deshalb Verfahren zur Merkmalsselektion verwendet, um ein reduziertes Merkmalsset zu erhalten und damit den Generalisierungsfehler zu reduzieren. Diese Verfahren weisen allerdings einige negative Eigenschaften wie eine hohe Varianz auf Grund diskreter Merkmalsselektion (Hastie et al., 2009) oder eine unvollständige Suche aller möglichen Merkmalskombinationen auf. Alternativ haben sich vor allem für Klassifikations- und Regressionsmodelle, mit einer Parameterschätzung über die Maximum-Likelihood Methode, Regularisierungsalgorithmen durchgesetzt, welche bestimmte Beschränkungen für die unbekannteten Modellparameter festlegen und damit ebenfalls anstreben den Generalisierungsfehler zu reduzieren. Die Regularisierung ist dabei integrativer Bestandteil der Parameterschätzung (Maximierung der Likelihood) und es ist, im Vergleich zur diskreten Merkmalsselektion (hard thresholding), eine kontinuierliche Gewichtung jedes Merkmals möglich (soft thresholding). Auf diese Verfahren wird im Folgenden genauer eingegangen.

Ein Maximum-Likelihood Schätzer ist immer erwartungstreu (ohne Bias) und hat minimale Varianz (*best linear unbiased estimator*, BLUE). Bei der Regularisierung (engl. auch *shrinkage*) besteht die Idee nun darin, eine Verzerrung des Schätzers (mehr Bias) in Kauf zu nehmen und dafür eine geringere Varianz zu erhalten. Für eine Inferenz (besonders bei einer Regression), d.h. die genaue Interpretation der geschätzten Parameterwerte, sind Verzerrungen allerdings unerwünscht. Soll ein Regressionsmodell jedoch zur Klassifikation verwendet werden, so interessieren nicht mehr vorrangig die einzelnen Regressionskoeffizienten, sondern die Klassifikationsperformance des gesamten Modells, weshalb eine leichte Verzerrung der Schätzer hier akzeptiert werden kann, wenn damit die Varianz der Schätzer verringert wird.

Der Einfluss von Bias und Varianz auf den erwarteten Vorhersagefehler kann an Hand eines generellen Regressionsmodells $Y = f(X) + \epsilon$ mit $\mathbb{E}(\epsilon) = 0$ und $Var(\epsilon) = \sigma_\epsilon^2$ erläutert werden. Für eine Schätzung $\hat{f}(X)$ auf Basis des Trainingssets $X = x_0$ ist der mittlere quadratische Fehler $Err(x_0)$ gegeben als (Hastie et al.,

2009)

$$\begin{aligned} Err(x_0) &= \mathbb{E}[(Y - \hat{f}(x_0))^2 | X = x_0] \\ &= \sigma_\epsilon^2 + [\mathbb{E}\hat{f}(x_0) - f(x_0)]^2 + \mathbb{E}[\hat{f}(x_0) - \mathbb{E}\hat{f}(x_0)]^2. \end{aligned} \quad (3.10)$$

Der zweite Term in Gleichung 3.10 ist der quadrierte Bias des Modells und der dritte Term stellt die Varianz von $\hat{f}(x_0)$ dar, welche durch abweichende Schätzungen $\hat{f}(X)$ auf Grund unterschiedlicher Trainingssets entsteht. Komplexere Modelle verringern den Bias, erhöhen aber gleichzeitig die Varianz. Regularisierung zielt darauf ab die Varianz der Schätzer zu reduzieren, indem die Modellparameter auf Werte näher an Null gezwungen werden. Die Reduktion der Varianz muss die gleichzeitige Erhöhung im Bias übersteigen, um den Vorhersagefehler zu verringern. Für Klassifikationsverfahren wird im Unterschied zu Gleichung 3.10 normalerweise das 0-1 Fehlermaß verwendet, was zu einem komplexeren Zusammenhang zwischen Bias und Varianz führt (Duda et al., 2000). Insbesondere entsteht hier für den Vorhersagefehler ein multiplikativer Zusammenhang von Bias und Varianz, wodurch sich eine Verringerung der Varianz noch stärker positiv auf den erwarteten Fehler auswirkt. Hinzu kommt, dass der Bias weniger Einfluss ausübt als beim mittleren quadratischen Fehler, da verzerrte Prädiktionen abseits der Entscheidungsgrenze keine Wirkung auf das 0-1 Fehlermaß haben (Hastie et al., 2009).

Lasso

Lasso (*Least Absolute Shrinkage and Selection Operator*) ist eine Form der Regularisierung, bei der der log-Likelihood-Funktion 3.9 ein Bestrafungsterm hinzugefügt wird, welcher Lösungen mit Koeffizientenwerten näher an Null bevorzugt. Gesucht wird der Parametervektor β , welcher den Ausdruck

$$\max_{\beta} \left\{ \sum_{i=1}^N [y_i \mathbf{x}_i' \beta - \log(1 + e^{\mathbf{x}_i' \beta})] - \lambda \sum_{j=1}^k |\beta_j| \right\} \quad (3.11)$$

maximiert (Hastie et al., 2009). Der letzte Term in 3.11 repräsentiert den Lasso-Bestrafungsterm, welcher über λ eine Obergrenze t für die Summe der L_1 -Normen der Regressionskoeffizienten festlegt ($\sum |\beta_j| \leq t$). Höhere Werte für λ führen zu einer stärkeren Regularisierung der Parameter zu Null hin, wohingegen sich für $\lambda = 0$ die Maximum-Likelihood-Schätzung ohne Regularisierung ergibt. Die Be-

sonderheit von Lasso besteht darin, bestimmte Koeffizienten exakt auf Null zu setzen. Dadurch wird eine Form kontinuierlicher Merkmalsselektion ermöglicht. Diese Tatsache kann durch Betrachtung der beschränkten Parameterregion für zwei Koeffizienten (s. Abbildung 3.6) veranschaulicht werden. Die beschränkte Region wird durch $\sum |\beta_j| \leq t$ aufgespannt. Zum Vergleich ist hier die beschränkte Region der Ridge-Regression ($\sum \beta_j^2 \leq t$, Hastie et al., 2009) ebenfalls gezeigt. Die Ridge-Regression ist eine der ältesten Regularisierungsformen mit einem quadratischen Bestrafungsterm β_j^2 . Wie in Abbildung 3.6 zu sehen ist, bevorzugt Lasso Lösungen, die auf einer der beiden Achsen liegen und somit den jeweils anderen Koeffizienten auf Null setzen. Ridge-Regression führt lediglich zu einer kontinuierlichen Skalierung beider Koeffizienten.

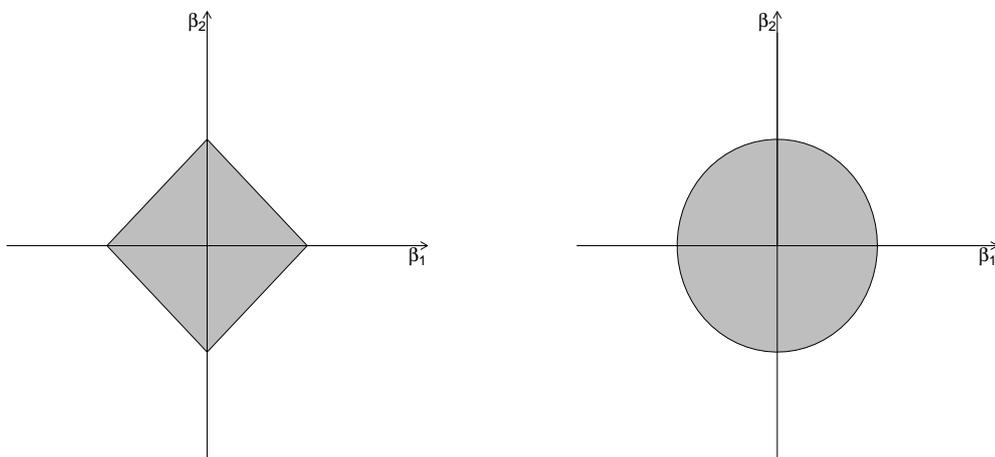


Abbildung 3.6: links: beschränkte Parameterregionen $|\beta_1| + |\beta_2| \leq t$ für Lasso, rechts: beschränkte Parameterregionen $\beta_1^2 + \beta_2^2 \leq t$ für Ridge-Regression.

Regularisierung kann auch im Kontext der Bayes-Parameterschätzung interpretiert werden (Tibshirani, 1996). Für Lasso ergibt sich als a-priori Verteilung der Regressionskoeffizienten β_j eine Laplace-Verteilung. Die Ridge-Regression resultiert hingegen in einer Normalverteilung. Abbildung 3.7 zeigt beide Verteilungen für einen Koeffizienten. Auch hier wird deutlich, dass Lasso Parameterwerte bevorzugt, die exakt Null sind. λ ist in diesem Zusammenhang invers proportional zur Varianz der a-priori Verteilung, d.h. ein hoher Wert für λ hat eine geringe Varianz der a-priori Verteilung zur Folge, wodurch Null-Werte wahrscheinliche Lösungen sind.

Die Bestimmung der β_i in 3.11 ist nicht-linear in y und hat deshalb keine geschlossene Lösung (Hastie et al., 2009). Eine effiziente Möglichkeit zur Berechnung

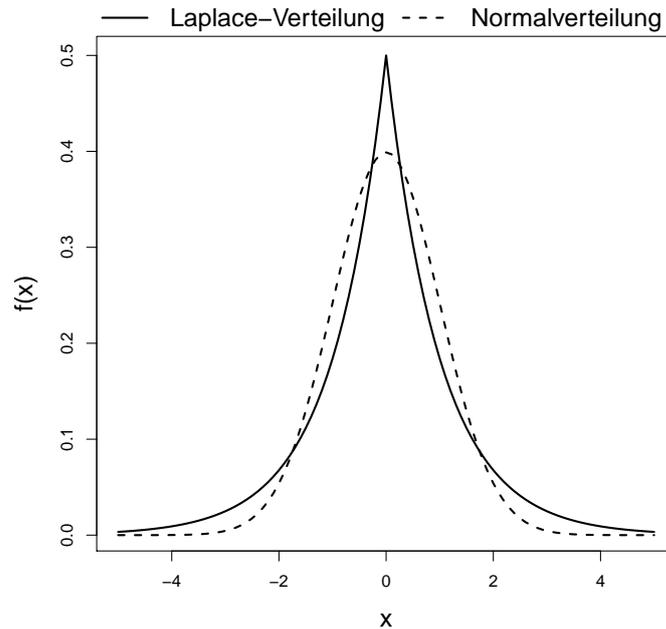


Abbildung 3.7: Die a-priori Verteilung der Regressionskoeffizienten für Lasso (Laplace-Verteilung) und Ridge-Regression (Normalverteilung).

von β_i besteht in einem iterativen Koordinatenabstieg, welcher im **R**-Paket **glmnet** implementiert ist (Friedman et al., 2010). Dieses Paket wurde für alle der folgenden Analysen verwendet.

Der optimale Wert für λ muss über eine Grid-Suche bestimmt werden. Dazu wird im Folgenden das λ mit maximalen AUC-Wert, basierend auf einer probandenweisen Kreuzvalidierung wie im vorherigen Abschnitt beschrieben, gewählt.

3.2.3 Ergebnisse

Zunächst muss der Umfang der Regularisierung bestimmt werden, also der Wert für λ , der die Klassifikationsperformance optimiert. Wie bereits beschrieben, muss dazu eine Grid-Suche über verschiedene λ erfolgen. Abbildung 3.8 zeigt AUC-Werte (ermittelt über probandenspezifische Kreuzvalidierung) gemittelt über 200 Stichproben, welche aus dem wiederholten, zufälligen Kürzen der Fahrdauern der Nicht-Abbrecher entstehen. Der Wert am linken Bildrand entspricht dem vollen logistischen Modell ohne Regularisierung ($\lambda = 0$). Mit zunehmender Regularisierung tritt eine Verbesserung der Klassifikationsperformance ein, welche ein Maximum von 0,845 bei $\log(\lambda) = -5,1$ erreicht. Zusätzliche Regularisierung führt wieder zu einer Abnahme der Performance. Ein Vergleich der AUC-Mittelwerte für das volle

Modell und die Lasso-Regularisierung mit $\log(\lambda) = -5,1$ mittels eines gepaarten t-Tests ergibt, eine signifikante Verbesserung der Performance für das regularisierte Modell ($T(199) = -21,9, p < 0,001$). In Abbildung 3.8 ist ebenfalls erkennbar, dass die Streuung der AUC-Werte am Maximum deutlich abnimmt, was auf eine verbesserte Generalisierbarkeit des Klassifikators hindeutet, da geringere Abweichungen in der Vorhersagegüte auf Grund des spezifischen Trainingssets auftreten.

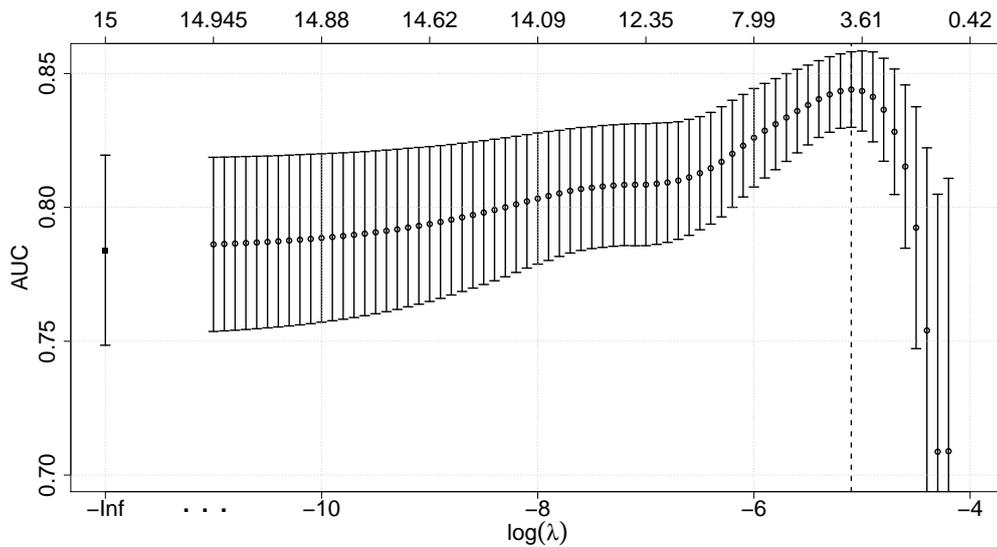


Abbildung 3.8: Mittlerer AUC-Wert für verschiedene λ der Lasso-Regularisierung. Die Fehlerbalken geben Standardabweichungen über die AUC-Werte der 200 Stichproben an. Die gestrichelte vertikale Linie kennzeichnet das Maximum. Die x-Achse oberhalb der Grafik gibt die mittlere Anzahl an Koeffizienten ungleich Null an.

In Abbildung 3.9 sind die Änderungen der einzelnen Regressionskoeffizienten bei Variation von λ visualisiert (Mittelwert über 200 Stichproben je λ und Koeffizient). Hier ist deutlich zu sehen, wie ein Großteil der Koeffizienten bei hohem λ auf Null gesetzt wird. Das AUC-Maximum bei $-5,1$ enthält nur noch vier Koeffizienten signifikant verschieden von Null. In Abbildung 3.10 sind Histogramme für jeden Regressionskoeffizienten über dessen Realisierungen in jeder der 200 Stichproben dargestellt. Eingetragen sind ebenfalls der Mittelwert und das 95%-Konfidenzintervall. Neben der Konstanten ist die Fahrtzeit relevant für die Klassifikation. Die Aufnahme der Fahrtzeit in das Regressionsmodell ist also gerechtfertigt und liefert einen validen Prädiktor für die Abbruchwahrscheinlichkeit. Der positive Regressionskoeffizient weist, wie zu erwarten war, auf eine Zunahme

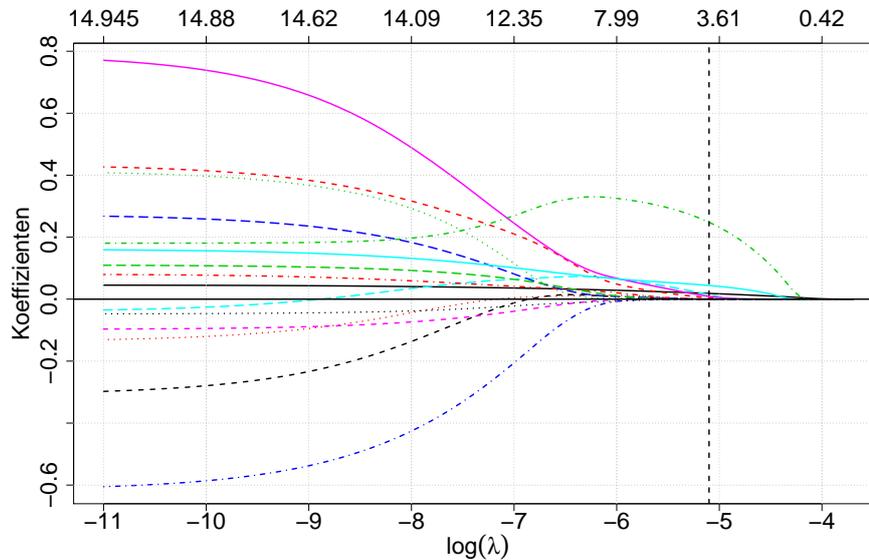


Abbildung 3.9: Regularisierung der Merkmale in Abhängigkeit von λ . Dargestellt sind Mittelwerte über 200 Stichproben je Merkmal und λ . Die gestrichelte vertikale Linie markiert das AUC-Maximum aus Abbildung 3.8 bei $\log(\lambda) = -5, 1$.

der Abbruchwahrscheinlichkeit mit steigender Fahrtdauer hin. Unabhängig von anderen erklärenden Variablen, steigt das Risiko des Abbruchs mit der Dauer der Fahrt, was auch augenscheinlich valide ist. Von den physiologischen Merkmalen sind nur die Spindeldauer an zentralen Elektroden und die Blinzeldauer signifikante Prädiktoren für die Abbruchwahrscheinlichkeit, wobei die Spindeldauer der wichtigste Prädiktor ist ($\beta = 0,248$). Die Ergebnisse in Abschnitt 2.3.3.2 zeigen ebenfalls eine signifikante Zunahme der Spindeldauer mit Ermüdung. Eine Verlängerung der Blinzeldauer mit ansteigender Müdigkeit wird von mehreren Studien bei Experimenten im Fahrkontext berichtet (Häkkanen et al., 1999; Ingre et al., 2006; Schleicher et al., 2008). Beide Merkmale stammen aus unabhängigen Merkmalsgruppen (EEG bzw. EOG). Die Merkmale innerhalb einer Gruppe sind stark korreliert, besonders zwischen den Kanalgruppen. Die Selektion genau dieser beiden Variablen durch Lasso bedeutet nicht zwingend, dass alle anderen Merkmale irrelevant für die Vorhersage des Abbruchs sind. Bei korrelierten Variablen tendiert Lasso zur Selektion nur einer dieser Variablen, wobei das Verfahren indifferent gegenüber der genauen Wahl des Prädiktors ist (Hastie et al., 2009). Will heißen, dass auch mit anderen Merkmalen ähnliche Klassifikationsergebnisse erzielt werden können, diese aber durch die besonderen Eigenschaften von Lasso

keine Beachtung finden. Tabelle 3.1 listet die Mittelwerte je Merkmal aller 200 Stichproben sowie die zugehörigen 95%-Konfidenzintervalle auf. Nur Fahrzeit, Spindeldauer (*durC*) und Blinzeldauer (*BLdur*) haben Regressionskoeffizienten signifikant verschieden von Null (Konfidenzintervalle, die die Null nicht beinhalten).

Merkmal	Mittelwert	95%-KI	
Intercept	-6,6553	(-7,311; -6,038)	*
Zeit	0,0185	(0,012; 0,026)	*
rateF	0,0045	(0; 0,059)	
rateC	0,0004	(0; 0)	
ratePO	0,0000	(0; 0)	
ampF	0,0143	(0; 0,067)	
ampC	0,0089	(0; 0,089)	
ampPO	0,0000	(0; 0)	
durF	0,0005	(0; 0,005)	
durC	0,2482	(0,194; 0,297)	*
durPO	0,0000	(0; 0)	
BLdur	0,0441	(0,034; 0,052)	*
BLfreq	0,0000	(0; 0)	
BLamp	0,0000	(0; 0)	
BLP80	0,0004	(0; 0,004)	
BLasym	0,0000	(0; 0)	

Tabelle 3.1: Mittelwerte der Regressionskoeffizienten und 95%-Konfidenzintervall. Koeffizienten verschieden von Null sind mit einem Stern markiert. Abkürzungen: *rate* - Spindelrate; *amp* - Spindelamplitude; *dur* - Spindeldauer; *F,C,PO* - Kanalgruppen (frontal, zentral, parieto-okzipital); *BL* - Blinzelparameter: *freq* - Frequenz; *P80* - PERCLOS80; *asym* - Asymmetrie

Abbildung 3.11 zeigt die vorhergesagten Abbruchwahrscheinlichkeiten über der Fahrzeit, getrennt gemittelt für Abbrecher und Nicht-Abbrecher. Der Anstieg der Abbruchwahrscheinlichkeit für beide Gruppen ist auf die Baseline-Wahrscheinlichkeit, durch Einführung der Fahrzeit als Merkmal, zurückzuführen. Weiterhin ist zu sehen, dass die Abbrecher ab ca. einer Stunde Fahrt eine stärkere Zunahme der Abbruchwahrscheinlichkeit erfahren, welche sich aus den spezifischen Eigenschaften der physiologischen Merkmale für Abbrecher ergibt. D.h. bereits vor dem eigentlichen Abbruch ist eine Zunahme der Wahrscheinlichkeit auf Grund der spezifischen, physiologischen Veränderungen zu verzeichnen, was den verschlechterten kognitiven Zustand des Fahrers durch starke Ermüdung repräsentiert. Ähnliche

Ergebnisse zeigt auch die statistische Analyse der Spindelmerkmale in Abschnitt [2.3.3.2](#), bei der eine stärkere Zunahme der Spindelrate, -dauer und -amplitude für die Abbrecher über der Zeit zu beobachten ist. Diese Merkmale, insbesondere die Spindeldauer, erweisen sich auch für die Vorhersage des Abbruchs in einem probandenunabhängigen Klassifikator als relevante Prädiktoren. Die Beschränkung auf die Spindeldauer durch die Lasso-Regularisierung ist kein Hinweis darauf, dass die übrigen Spindelmerkmale keine abbruchrelevante Information enthalten. Vielmehr ist es der spezifischen Eigenschaft des Lasso-Verfahrens zuzuschreiben, dass nur einer von dieser Gruppe korrelierter Prädiktoren selektiert wird. Es sei darauf hingewiesen, dass dem Klassifikator die Information zu welcher Probandengruppe eine Testperson gehört nicht zur Verfügung steht. Die unterschiedlich großen Standardfehler erklären sich durch verschieden große Stichproben, über die zu jedem Zeitpunkt gemittelt wird, da mit zunehmender Fahrtzeit nicht mehr alle Datensätze bereit stehen.

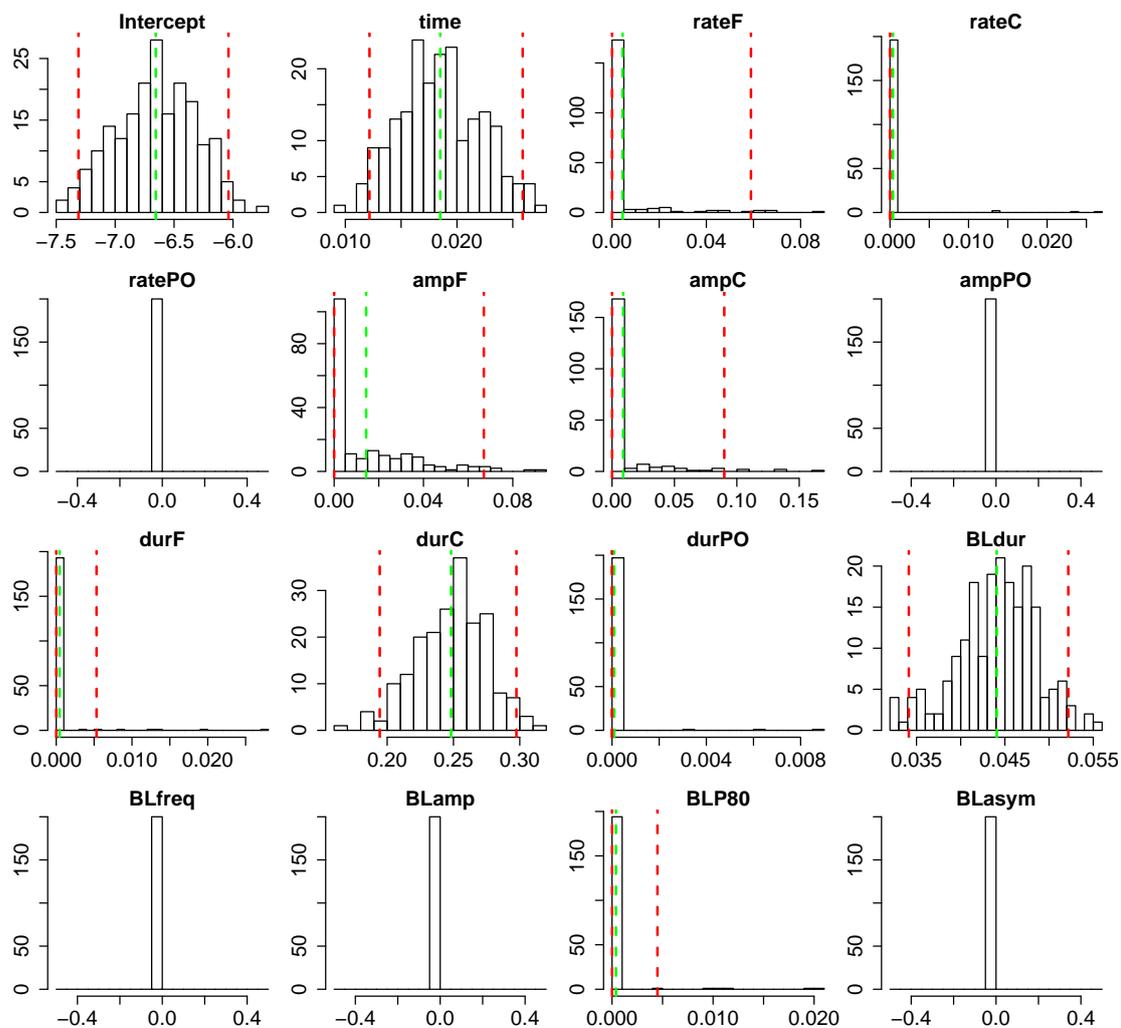


Abbildung 3.10: Histogramme der Regressionskoeffizienten für jedes Merkmal über 200 Modellschätzungen. grüne Linie: Mittelwert, rote Linien: 95%-Konfidenzintervall. Nur vier Koeffizienten sind verschieden von Null.

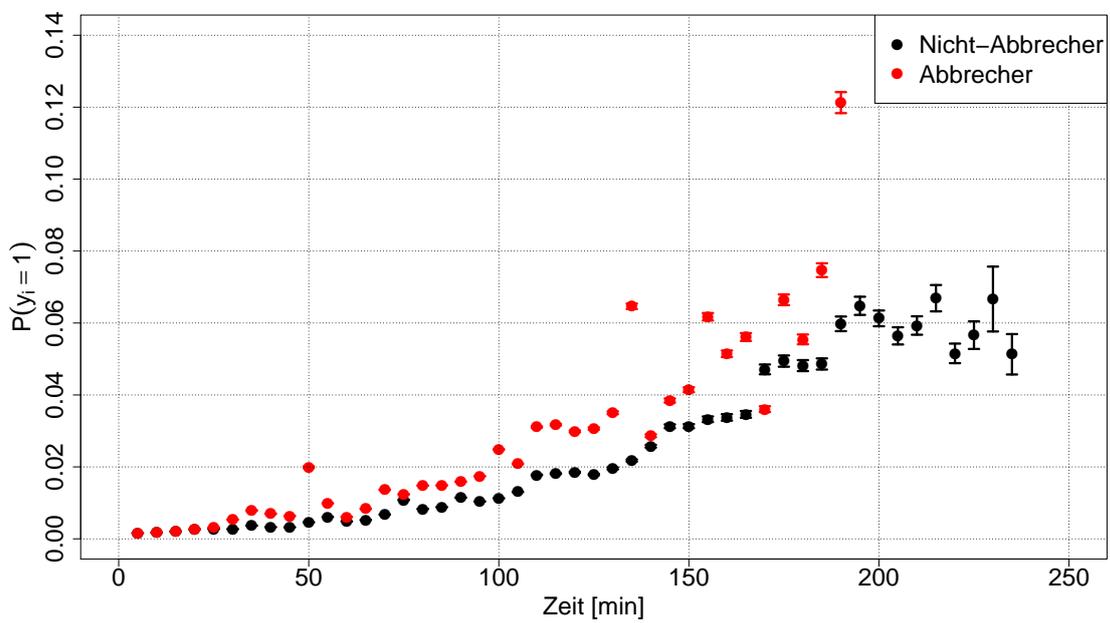


Abbildung 3.11: a-posteriori Wahrscheinlichkeit für einen Fahrtabbruch getrennt nach Probandengruppen (Abbrecher, Nicht-Abbrecher).

Kapitel 4

Artefakte im EEG

Die Aufzeichnung neuronal generierter elektrischer Felder mittels EEG ist eine hochsensible Messung. Die Messwerte der elektrischen Potentiale bewegen sich an der Schädeloberfläche im Bereich von $5\ \mu\text{V}$ bis wenige hundert Mikrovolt ([Zschocke, 2002](#)). Moderne rauscharme Hochimpedanz-Differenzverstärker erlauben eine, aus technischer Sicht, qualitativ hochwertige Registrierung dieser geringen Potentialschwankungen. Problematisch bleiben allerdings biologische Signale nicht-neuronalen Ursprungs (Artefakte), welche an der EEG-Elektrode einkoppeln und als additive Mischung zusammen mit dem Nutzsignal aufgezeichnet werden. Die nachträgliche Separierung solcher Störungen von den eigentlichen EEG-Signalanteilen erfordert eine intelligente Signalverarbeitung und ist bis heute nicht vollständig gelöst.

Problematisch ist hierbei besonders die hohe Energie der Artefakte. Mit dem EEG aufgezeichnete Störungen erreichen häufig Amplituden im Millivolt Bereich und übertreffen damit die neuronale Signalenergie um ein Vielfaches. Dementsprechend ist eine direkte Analyse des EEGs in artefaktbehafteten Segmenten nicht mehr möglich, da das Artefakt die Signalcharakteristiken des Segmentes dominiert.

Die spektralen Eigenschaften von Artefakten sind sehr unterschiedlich. Bestimmte technische Artefakte, z.B., Einkopplungen von Transformatoren (Netzbrummen), haben ein sehr schmalbandiges, stabiles Spektrum, wohingegen Artefaktquellen physiologischer Natur (z.B. Muskelaktivität) oft ein sehr breites Spektrum, ähnlich farbigem Rauschen haben. Die Vielzahl von Artefakten bewirkt, dass das gesamte EEG-Spektrum überlagert wird, von niedrigfrequenten (z.B. Augenbewegungen: Delta- bis Alpha-Band) bis hochfrequenten, breitbandigen Störungen (z.B. Muskelaktivität: Alpha- bis Gamma-Band, [Goncharova et al., 2003](#)).

Somit sind nahezu alle Formen der EEG-Analyse (z.B. Spektralanalyse, evozierte Potentiale) von Artefakten betroffen und erfordern eine mehr oder weniger aufwendige Behandlung von Störungen.

Die effektivste Methode, um EEG-Messungen zu verbessern, ist die Vermeidung von Artefakten bei der Aufzeichnung. Dies kann durch verschiedene technische Maßnahmen, wie z.B. elektromagnetische Abschirmung von EEG-Laboren und Elektrodenkabeln, Notch-Filtern oder aktive Elektroden mit integrierter Rauschunterdrückung (z.B. BrainProducts actiCap) erzielt werden. Außerdem kann das Verhalten des Probanden wesentlich zur Vermeidung von Artefakten beitragen. Wenig Bewegung, insbesondere im Kopfbereich, entspannte Muskulatur und möglichst geringe okuläre Aktivität helfen biologische Artefakte zu vermeiden. Sowohl die experimentelle Aufgabe als auch die Kooperationsbereitschaft des Probanden setzen hier allerdings Grenzen. Ebenso lassen sich nicht alle technischen Störungen vermeiden, bzw. sind im Vorfeld des Experimentes bekannt.

Eine besondere Situation stellt die Aufzeichnung des EEGs im Fahrzeug und vor allem im realen Straßenverkehr dar. Hier ist es nicht möglich Kopf- und Augenbewegungen einzuschränken. Der Proband ist sogar wesentlich aktiver als bei konventionellen EEG-Versuchen im Labor. Die damit verbundene Augen- und Muskelaktivität führt zu zahlreichen Artefakten im EEG, welche bei der weiteren Verarbeitung berücksichtigt werden müssen. Beispielsweise kneift der Fahrer bei frontaler, tief stehender Sonne häufig die Augen zusammen, was an frontalen Elektroden starke und lang andauernde Muskelartefakte hervorruft. Kurze Unterhaltungen, welche sich nicht vermeiden lassen, sowie Gähnen führen ebenfalls zu starken biologischen Artefakten. Blicke in die Außenspiegel sowie Schulterblicke führen durch Kontraktion der Nackenmuskulatur zu Muskelartefakten an posterioren Elektroden. Bedingt durch die Aktivität des Probanden werden auch die Elektrodenkabel der EEG-Haube bewegt, was zu technischen Störungen führen kann, besonders wenn dabei eine Elektrode (auch nur leicht) relativ zur Kopfhaut verschoben wird, da hierdurch starke Impedanzschwankungen auftreten. Es kommt häufig vor, dass der Proband den Kopf zurücklehnt und dadurch die EEG-Haube mit der Kopfstütze in Kontakt kommt. Die damit verbundene Bewegung der Elektroden ist ebenfalls kritisch und führt zu starken Störungen. In den Experimenten im Fahrzeug treten weiterhin technische Einstreuungen auf, die aus dem Labor nicht bekannt sind. Das Einschalten der Sitzheizung führt z.B. zu massiven Einkopplungen. Ebenfalls ungewöhnlich sind transiente 16,6 Hz und 50 Hz Störungen, welche bei Durchfahrten unter Eisenbahnlinien und Hochspannungslei-

tungen auftreten, da das starke elektrische Feld in die EEG-Messung einkoppelt. Abbildung 4.1 zeigt einige Beispiele von biologischen und technischen Artefakten, welche bei EEG-Aufzeichnungen im Fahrzeug entstehen.

4.1 Artefaktdetektion vs. Artefaktbereinigung

4.1.1 Artefaktdetektion

Bei der Behandlung von Artefakten im EEG gibt es zwei grundsätzlich unterschiedliche Vorgehensweisen. Mit der Detektion von Artefakten werden kontaminierte Segmente identifiziert und von der weiteren Verarbeitung ausgeschlossen. Dieses Verfahren wird meist für Daten die in Epochen gegliedert sind verwendet (z.B. ereigniskorrelierte Potentiale). Es ist bis heute üblich artefaktbehaftete Epochen durch visuelle Inspektion der Rohdaten zu identifizieren, was allerdings sehr zeitaufwändig ist und von der subjektiven Einschätzung des EEG-Experten abhängt. Ein Nachteil dieses Verfahrens ist der Datenverlust, der durch die Elimination der Artefaktsegmente entsteht. Besonders beim manuellen Vorgehen wird üblicherweise keine individuelle Klassifizierung pro Kanal getroffen, sodass Kanäle ohne Störung in einem Segment ebenfalls verloren gehen. Hinzu kommt, dass bestimmte Artefakte (z.B. Blinzeln) mit der experimentellen Aufgabe korrelieren können und dadurch relevante Datensegmente systematisch verworfen werden.

Automatisierte Verfahren zur Detektion von Artefakten haben sich in den letzten Jahren immer mehr etabliert. Beispielsweise sind in der EEGLab-Toolbox für Matlab (Delorme und Makeig, 2004) verschiedene Kriterien zur Identifikation von Epochen mit Artefakten implementiert. Dazu zählen u.a. statistische Maße wie Kurtosis und Wahrscheinlichkeitsverteilungen anhand der empirischen Dichtefunktion der Amplituden, Schwellwertdetektoren für hohe Amplituden und starke Gradienten sowie die Ausnutzung typischer spektraler Muster von Artefakten (Delorme et al., 2007).

Die Artefaktdetektion in kontinuierlichen EEG-Aufzeichnungen ist für die Daten, die im Rahmen dieser Arbeit entstanden sind, von größerem Interesse, da keine repetitiven, trial-basierten Experimente durchgeführt wurden und somit keine Unterteilung in Epochen möglich ist. Verfahren zu dieser Problematik werden in Kapitel 4.4 ausführlich diskutiert.

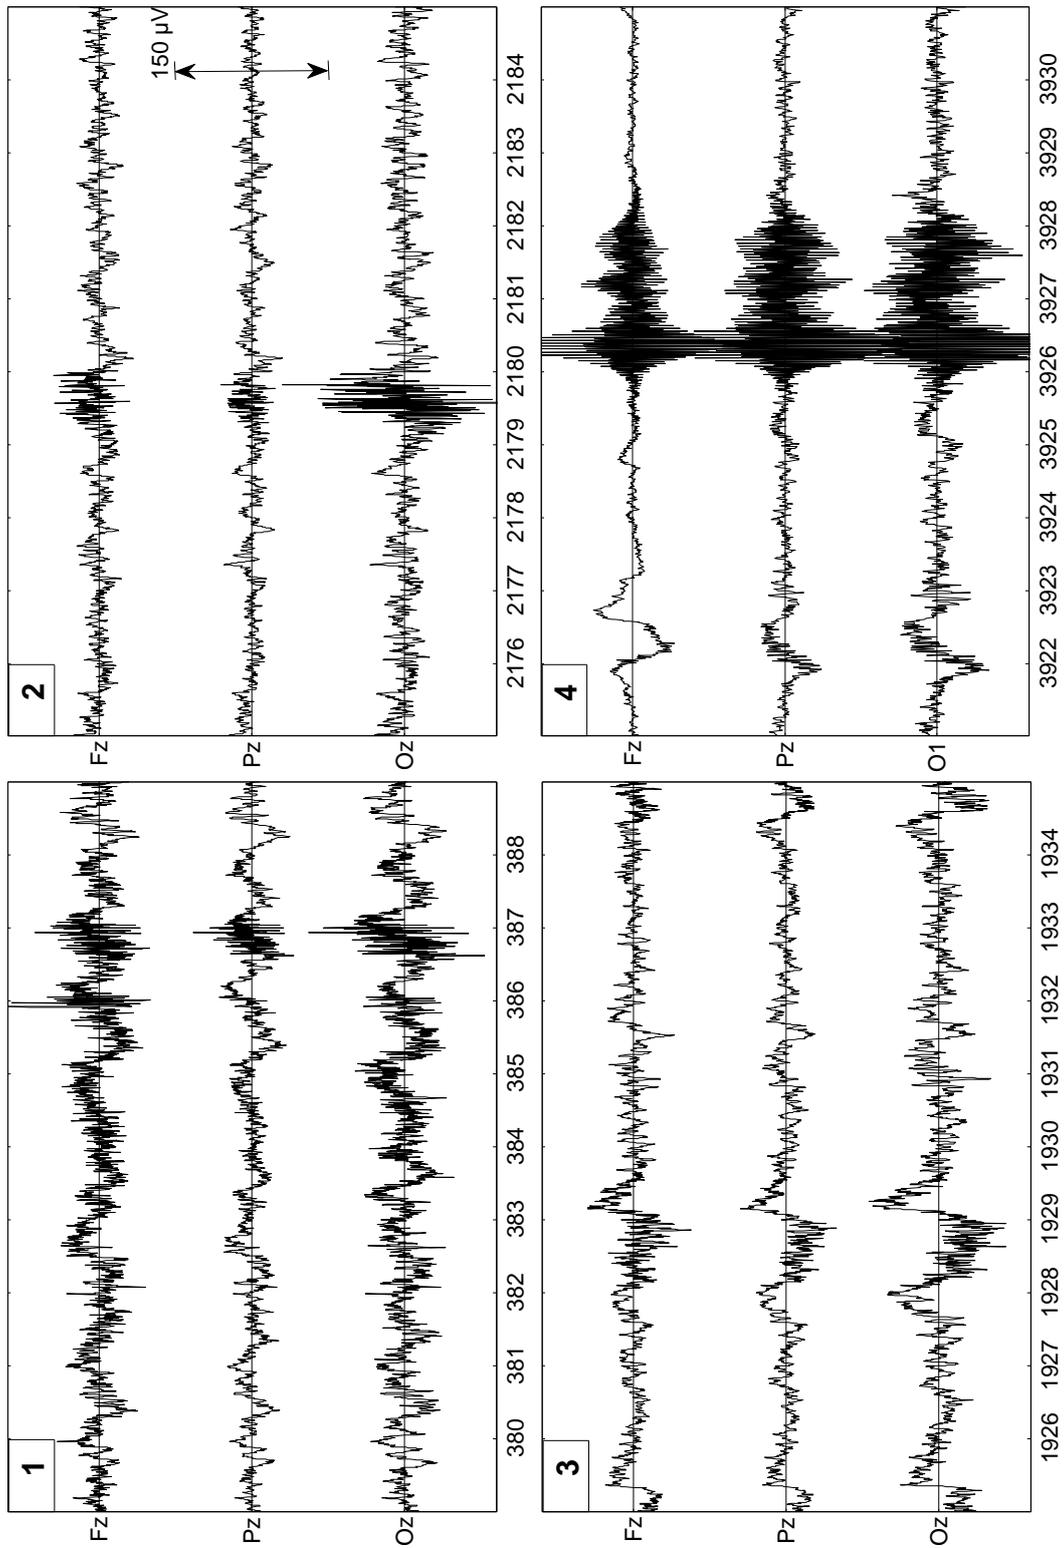


Abbildung 4.1: Beispiele von Artefakten. 1: Gähnen; 2: Schulterblick; 3: Augen zusammen kneifen; 4: Durchfahrt unter Hochspannungsleitung. x-Achse: Zeit in sec

4.1.2 Artefaktbereinigung

Mit der Artefaktbereinigung wird das Ziel verfolgt die Superposition von neuronalen Signalen und Störsignalen bestmöglich rückgängig zu machen und den artefaktbehafteten Signalanteil herauszufiltern. Gelingt die Separation hinreichend gut, können zuvor kontaminierte Datenabschnitte für nachfolgende Analysen verwendet werden. Es tritt also kein Datenverlust auf. Bei akzeptabler Präzision des Verfahrens ist dies natürlich die Methode der Wahl, allerdings gibt es bei den bisherigen Verfahren nach wie vor Einschränkungen in der Anwendbarkeit und eine in nicht allen Fällen zufriedenstellende Performance.

Für Artefakte, die durch Augenbewegungen (Sakkaden, Blinzeln) an EEG-Elektroden aufgezeichnet werden, hat sich schon früh ein Regressionsverfahren zur Reduktion der Störungen etabliert (Gratton et al., 1983; Croft und Barry, 2000). Dieses Verfahren setzt voraus, dass das Störsignal separat (d.h. ohne Einstrahlung von EEG-Aktivität) registriert werden kann, was bei Augenbewegungen durch die Aufzeichnung des EOGs prinzipiell möglich ist. In Kapitel 4.3 wird die Methode detailliert beschrieben. Für Muskelartefakte lässt sich dieses Verfahren nicht anwenden, da die Vielzahl aktiver Muskeln im Kopfbereich deren separate Registrierung nicht möglich macht.

In den letzten Jahren hat die Independent Component Analysis (ICA) für die Artefaktbereinigung von EEG-Signalen verstärkt Verbreitung erfahren (Jung et al., 1996; Lee et al., 1999; Joyce et al., 2004). Die Grundannahme ist hierbei, dass EEG- und Störsignale, welche als lineare Mischung an einer Elektrode auftreten, statistisch unabhängig sind, da sie von verschiedenen unabhängigen Signalquellen stammen. Die ICA versucht nun, ohne Kenntnisse der Quellencharakteristika (blind), eine Transformation zu finden, welche die statistische Unabhängigkeit zwischen den transformierten Signalen maximiert (Hyvärinen et al., 2001). Es wird angenommen, dass sich in den transformierten Signalen die Quellensignale möglichst gut abbilden. Im transformierten Quellenraum können nun Störquellen verschiedener Art identifiziert und eliminiert werden. Die so bereinigten Quellensignale können anschließend in den ursprünglichen Signalraum rücktransformiert werden, wobei Signalanteile mit Artefakten herausgefiltert werden.

Die ICA ist besonders effektiv bei der Bereinigung von Augenbewegungen (Vigário, 1997; Joyce et al., 2004), da sich die Augenaktivität meist in einer oder nur wenigen Komponenten, klar getrennt von neuronalen Quellen, abbildet. Grund hierfür ist einerseits die Möglichkeit das Quellensignal mittels EOG getrennt auf-

zuzeichnen und andererseits die häufig wiederkehrenden stereotypen Muster der Augenbewegung (z.B. Blinzler), wodurch gute Schätzungen der statistischen Charakteristika der Quelle möglich sind, was wiederum für eine gute Quellenseparation notwendig ist. Eine Bereinigung des EEGs von Muskelaktivität, EKG-Artefakten und Netzbrummen ist mit Hilfe der ICA ebenfalls möglich (Jung et al., 2000; Fitzgibbon et al., 2007). Muskelaktivität ist auf Grund der zahlreichen Quellen schwieriger zu separieren. Häufig verteilt sie sich auf mehrere Komponenten (Halder et al., 2007), teils gemischt mit neuronalen Signalen. Eine vollständige Bereinigung von Muskelartefakten ist somit nicht mehr möglich, außer ein Verlust von EEG-Anteilen wird in Kauf genommen.

Die Artefaktbereinigung mit ICA benötigt normalerweise einen manuellen Zwischenschritt, bei dem die Komponenten, welche Artefakte repräsentieren ausgewählt werden müssen. Bei Studien mit großer Probandenzahl kann dies sehr zeitaufwändig sein. Außerdem ist die Selektion wieder von subjektiven Auswahlkriterien bestimmt. In neuerer Zeit sind allerdings Methoden vorgestellt worden, die eine automatisierte Auswahl von Artefaktkomponenten durchführen können (Mognon et al., 2011), wobei spektrale und topographische Merkmale der Artefakte ausgenutzt werden.

Die ICA ist per se ein offline-Verfahren, da zur Quellentrennung statistische Kennwerte der gesamten Aufzeichnung berechnet werden müssen. Es besteht zwar die Möglichkeit die ICA in Segmenten zu berechnen und damit in einem gleitenden Fenster in Echtzeit anzuwenden, allerdings besteht für jedes Segment weiterhin die Problematik der Komponentenselektion. Da, abhängig von den ICA-Ergebnissen, eine unterschiedlich starke Artefaktbereinigung in sukzessiven Segmenten erfolgt, können der EEG-Zeitreihe dadurch Nicht-Stationaritäten künstlich zugefügt werden, was unerwünschte Einfluss auf die nachfolgenden Analysen haben kann.

Da eine vollständige Artefaktbereinigung von EEG-Daten mittels ICA meist nicht möglich ist, ist eine Detektion von verbliebenen Artefakten, die nicht eliminiert werden können, weiterhin sinnvoll, um deren Einfluss auf nachfolgende Analysen zu minimieren.

Unvermeidliche und teils unerwartete Artefakte machen eine Behandlung von Artefakten in EEG-Aufzeichnungen im Fahrzeug unerlässlich. Deshalb werden im Rahmen dieser Arbeit verschiedene echtzeitfähige Verfahren zur Artefaktbereinigung und Detektion implementiert und evaluiert. Ziel ist hierbei insbesondere die Arbeit mit kontinuierlichen Daten, mit kanalweiser Bereinigung bzw. Detektion und hoher zeitlicher Auflösung. Da für Augenbewegungen durch das EOG

ein gutes Referenzsignal der Störungen vorliegt, wird eine Echtzeitbereinigung von EOG-Artefakten verfolgt. Für Artefakte aus Muskelaktivität und technischen Störungen wird eine Detektion in Echtzeit angestrebt.

4.2 Grundlagen

Der folgende Abschnitt gibt einen kurzen Überblick über die theoretischen Grundlagen zur Entstehung von biologischen und technischen Artefakten im EEG.

4.2.1 Biologische Artefakte

Biologische Artefakte entstehen an Orten elektromagnetischer Aktivität innerhalb des Körpers. Dies sind vor allem die Augen und Muskeln im Kopfbereich sowie der Herzmuskel. Durch Volumenleitung wird das elektrische Potential von der Artefaktquelle zur EEG-Elektrode weitergeleitet und erfährt hierbei eine Dämpfung proportional zum quadratischen Abstand zwischen Elektrode und Artefaktquelle ([Malmivuo und Plonsey, 1995](#)). Die EEG-Elektrode registriert schließlich eine lineare Mischung aus neuronalen Potentialen und Artefaktpotentialen. Die gängigen Verfahren zur Bereinigung des EEGs von Artefakten (Regression, ICA) bauen auf der Annahme der linearen Superposition auf.

Okulare Artefakte

Das Auge besitzt ein statisches elektrisches Potential, mit einem negativen Pol in der Retina und einem positiven Pol in der Kornea. Das Potential entsteht durch metabolische Vorgänge in der Retina und liegt im Bereich von 0,4–1 mV ([Malmivuo und Plonsey, 1995](#)). Beide Augen besitzen einen gleichartigen Dipol, welche sich im Normalfall synchron bewegen. Bei der Bewegung der Augen werden beide Dipole rotiert und das sich ändernde elektrische Umgebungspotential breitet sich durch Volumenleitung über den Kopf aus. Blinzeln, d.h. das kurze Schließen des Augenlides, resultiert ebenfalls in Potentialänderungen, da das sich über die Kornea legende Augenlid zu einer Änderung der elektrischen Leitfähigkeit führt ([Matsuo et al., 1975](#); [Iwasaki et al., 2005](#)). Diese Effekte werden beim Elektrookulogramm (EOG) ausgenutzt, um sowohl Bewegungen der Augen als auch Blinzeln zu registrieren. Potentialschwankungen auf Grund von Augenbewegungen lassen sich bis in okzipitale Elektroden beobachten ([Croft und Barry, 2000](#)).

In EEG-Aufzeichnungen sind vor allem horizontale und vertikale Sakkaden sowie Augenblinzeln deutlich sichtbar. Okulare Artefakte verursachen hauptsächlich im niederfrequenten Spektralbereich Störungen im EEG (Delta- bis Alpha-Band), wobei schnelle Sakkaden Spektralanteile bis 30 Hz aufweisen können (Bahill et al., 1981).

Muskelartefakte

Bei der Kontraktion eines Muskels werden, über die Erregung der Nervenfasern, Aktionspotentiale im Motoneuron und den zugehörigen Muskelfasern erzeugt, was zu kurzen Zuckungen des Muskels führt. Bei länger andauernder Kontraktion werden die Motoneuronen kurz hintereinander repetitiv erregt (Birbaumer und Schmidt, 2006). Die Kontraktion eines Muskels beinhaltet außerdem die asynchrone Aktivierung mehrerer Motoneuronen und deren Muskelfasern. Die Summe dieser Vorgänge führt zu den typischen Potentialen, welche an der Haut oberhalb des Muskels durch Elektroden abgeleitet werden können (Elektromyografie, EMG). Die Höhe des gemessenen Potentials ist von der Größe des Muskels und dem Grad der Anspannung abhängig. Elektromyografische Einstreuungen an EEG Elektroden werden vor allem durch die Stirn-, Kiefer und Nackenmuskulatur erzeugt. Typische Bewegungen sind dabei z.B. Stirnrunzeln, Augenkneifen, Gähnen, Sprechen, auf die Zähne beißen oder starke Kopfdrehungen wie z.B. ein Schulterblick.

Muskelartefakte zeichnen sich durch ein breites, rauschähnliches Spektrum aus, was zu Störungen des EEGs in nahezu allen Frequenzbereichen führt (Delta- bis Gamma-Band, Goncharova et al., 2003), wobei der größte Teil der Signalenergie zwischen 20 Hz und 40 Hz liegt. Erschwerend für die Bereinigung bzw. Detektion kommt hinzu, dass die Signaleigenschaften zwischen verschiedenen Muskeln und unterschiedlichen Kontraktionsgraden variieren. Beispielsweise steigt die Frequenz der Maximalamplitude mit dem Grad der Muskelanspannung, jedoch ist die Ausprägung dieses Effekts für frontalis (Stirn) und temporalis (Kiefer) Muskeln verschieden. Topografisch betrachtet sind vor allem frontale und temporale EEG-Elektroden betroffen, wobei starke Kontraktionen alle EEG-Elektroden beeinflussen können (Goncharova et al., 2003).

4.2.2 Technische Artefakte

Zu den technischen Artefakten zählen alle Störungen, welche außerhalb des Körpers generiert werden oder durch Fehlfunktionen der Messapparatur entstehen. Externe Störquellen sind vor allem das Netzbrummen, was einen scharfen Frequenzpeak bei 50 Hz bzw. 60 Hz hervorruft. Netzbrummen lässt sich allerdings effektiv durch einen Notch-Filter unterdrücken. Im Fahrzeug können weitere Störquellen auftreten. Dies sind z.B. Einstreuungen durch die Sitz- bzw. Lenkradheizung oder diverse Spannungswandler, der in den Versuchsträgern zusätzlich integrierten Fahrzeug-Messtechnik. Auffällig sind in den Experimenten weiterhin sporadische Einstreuungen bei Durchfahrten unter Hochspannungsleitungen und Eisenbahnlinien (50 Hz bzw. 16,67 Hz).

Die magnetischen Felder externer Quellen koppeln hauptsächlich durch magnetische Induktion über eine Leiterschleife ein, welche zwischen Referenzelektrode und Messelektrode entsteht (Ferree et al., 2001). Ein kapazitives Einkoppeln elektrischer Felder ist ebenfalls möglich und wird primär durch Impedanzunterschiede zwischen Mess- und Referenzelektrode hervorgerufen.

Weitere Störungen treten bei Bewegung der Elektroden auf, da hier die Impedanz zwischen Schädel und Elektrode, durch Bewegung des Kontaktgels, stark schwankt. Löst sich eine Elektrode oder ein Kabel, treten hohe Amplituden mit niedrigen Frequenzen sowie Sprungstellen im Signal auf.

4.3 EOG-Bereinigung

Wie in der Einleitung bereits erwähnt wurde, lassen sich Artefakte durch Augenbewegungen mit einem Regressionsverfahren beseitigen bzw. reduzieren. Ein großer Teil der EEG-Studien berichtet heute zwar die Verwendung der ICA zur Bereinigung von EEG-Daten, allerdings sind die Ergebnisse von Evaluationsstudien, welche die Qualität der EOG-Bereinigung zwischen ICA und Regression vergleichen nicht eindeutig. In der Arbeit von Schlögl et al. (2009) werden Regressionsverfahren und ICA-Methoden mit automatischer Erkennung der Komponenten, welche okulare Artefakte enthalten, verglichen. Basierend auf spektralen Performancemaßen, kommen die Autoren zu dem Schluss, dass Regressionsverfahren für eine vollautomatische Bereinigung bessere Ergebnisse gegenüber der ICA liefern. Zum gleichen Ergebnis kommt auch eine Studie von Klados et al. (2008), in welcher ein adaptiver Filter als Regressionsverfahren verwendet wird und nur die

Reduktion von Blinzelartefakten betrachtet wird. Die Studie von [Hoffmann und Falkenstein \(2008\)](#) findet eine vergleichbare Performance bei der Bereinigung von Blinzelartefakten zwischen Regression und ICA. Die Analyse von [Romero et al. \(2009\)](#) ergibt hingegen eine bessere Performance für die ICA. Auf Grund dieser Studien kann keiner Methode eindeutig der Vorzug gegeben werden und es ist anzunehmen, dass beide Verfahren eine vergleichbare Performance liefern können, welche vermutlich stark von den Signaleigenschaften abhängt. Unterschiede zwischen den Studien lassen sich vermutlich auf abweichende Performancemaße und unterschiedliche experimentelle Setups zurückführen.

Weiterhin besitzt die Variante über eine Regression einige wichtige Vorteile gegenüber der EOG-Bereinigung mit ICA, wodurch sich dessen Verwendung in bestimmten Anwendungssituationen, unabhängig von Performanceunterschieden anbietet. Im Rahmen dieser Arbeit wird vor allem ein Verfahren gesucht, welches die EOG-Bereinigung in Echtzeit durchführt und dabei wenig Kalibrationsaufwand benötigt. Die Regression bietet sich hier an, da sie, im Gegensatz zur ICA, ohne manuelle Zwischenschritte auskommt und nur eine kurze Baseline zur Bestimmung der Regressionskoeffizienten benötigt. Danach lässt sich das EEG mit geringem Rechenaufwand in Echtzeit bereinigen.

Zur Bereinigung des EEGs von okularen Artefakten wird auf das Prinzip der linearen Mischung von neuronalen Quellen und okularen Einstreuungen an der Messelektrode zurückgegriffen. Die Bereinigung erfolgt über eine multiple Regression ([Schlögl et al., 2007](#)), hier wiedergegeben in der üblichen Notation für allgemeine lineare Modelle ([Fahrmeir et al., 2007](#)):

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}_Q, \quad (4.1)$$

mit $\mathbf{Y}, \boldsymbol{\epsilon}_Q \in \mathbb{R}^{T \times C}$, $\mathbf{X} \in \mathbb{R}^{T \times 2}$ und $\boldsymbol{\beta} \in \mathbb{R}^{2 \times C}$. T gibt die Länge der Messung in Samples an und C die Anzahl der EEG-Kanäle. \mathbf{Y} ist die Matrix der Messwerte aller EEG-Kanäle, \mathbf{X} sind die Messwerte der vertikalen und horizontalen EOG-Kanäle und $\boldsymbol{\epsilon}_Q$ ist der Fehlerterm der Regression, welcher in diesem Zusammenhang als die wahren neuronalen Quellensignale ohne EOG-Überlagerung angesehen werden kann, denn dies ist der Anteil der EEG-Signale, welcher nicht durch das EOG erklärt wird. Die Regressionskoeffizienten $\boldsymbol{\beta}$ repräsentieren die Dämpfung der EOG-Signale an der jeweiligen EEG-Elektrode. Das Regressionsmodell kann folgendermaßen interpretiert werden: Mit Hilfe des Regressors \mathbf{X}_i wird versucht die EEG-Aktivität an einem Kanal \mathbf{Y}_j zu erklären. Der erklärbare Anteil

sind EOG-Potentiale, welche durch Volumenleitung an der EEG-Elektrode aufgezeichnet werden. Der nicht-erklärbare Anteil ϵ_{Q_j} ist die neuronale EEG-Aktivität, welche durch

$$\hat{\epsilon}_Q = \mathbf{Y} - \mathbf{X}\hat{\beta} \quad (4.2)$$

rekonstruiert werden kann und das von EOG-Artefakten bereinigte EEG darstellt. β bestimmt sich über den KQ-Schätzer zu (s. Abschnitt 2.4.2.1)

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}. \quad (4.3)$$

Die multiple Regression berücksichtigt mögliche Korrelationen zwischen den EOG-Komponenten, sodass keine Mehrfachkorrektur gleicher Signalanteile auftreten kann.

Problematisch beim Regressionsansatz ist die Einstreuung von EEG-Aktivität in EOG-Signale, wie sie z.B. durch frontale, kortikale Quellen oder eine nicht-neutrale Referenzelektrode auftreten kann (z.B. an FCz). Wird ein solches EOG-Signal zur Korrektur verwendet, können Teile der relevanten EEG-Aktivität an den zu bereinigenden EEG-Elektroden ebenfalls entfernt werden. Um diese mögliche Überkompensation zu vermeiden, wird das EOG bipolar abgeleitet. Dabei wird für das vertikale EOG die Differenz einer Elektrode über dem Auge gegen eine Elektrode unter demselben Auge bestimmt und für das horizontale EOG die Differenz zweier Elektroden am linken und rechten Canthus (Schlögl et al., 2007). Da EOG-Aktivität an den Elektrodenpaaren in entgegengesetzter Polarität auftritt, wird diese durch die bipolare Ableitung verstärkt und EEG-Aktivität, die an beiden Elektroden auftritt eliminiert. Durch die größere posteriore Entfernung von neuronalen Quellen zu den EOG-Elektroden sind die neuronalen Potentiale an beiden EOG-Elektroden sehr ähnlich, da die sagittale Lage der Quelle maßgeblich das gemessene Potential bestimmt und die laterale Lage, d.h. die Asymmetrie zu den EOG-Elektroden, nur geringen Einfluß hierauf hat. Daher löschen sich die Potentiale weit entfernter neuronaler Quellen bei bipolarer EOG-Ableitung größtenteils aus. Abbildung 4.2 zeigt die schematische Anordnung der EOG-Elektroden für eine bipolare Ableitung.

Abbildung 4.3 zeigt den Einfluss einer nicht neutralen Referenzelektrode (Mastoid), welche EEG-Aktivität auffängt, auf die EOG-Kanäle bei unipolarer Ableitung. Alpha-Aktivität ist deutlich sichtbar und kann durch die bipolare Ableitung entfernt werden, wodurch eine Überkompensation dieser Aktivität an den EEG-

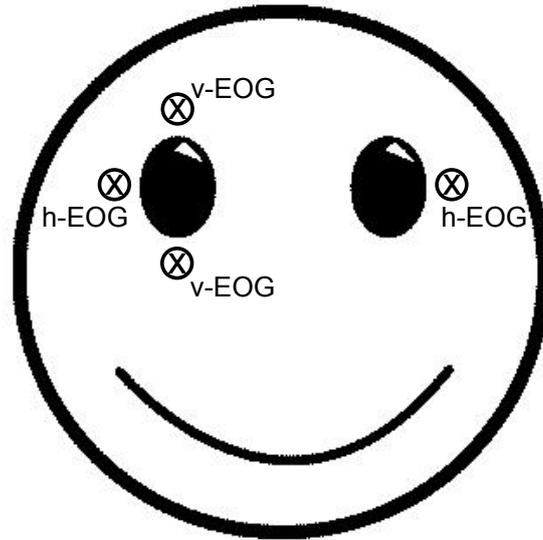


Abbildung 4.2: Elektrodensetup für die Ableitung des EOG. Vertikale (v-EOG) und horizontale (h-EOG) Elektroden werden jeweils gegeneinander referenziert.

Elektroden bei der EOG-Bereinigung durch Regression vermieden wird. Da EOG-Aktivität nur niedrige Frequenzen aufweist, können durch eine Tiefpassfilterung im Bereich von 20–30 Hz zusätzlich höherfrequente EEG-Signale herausgefiltert und Überkompensation damit ausgeschlossen werden.

Zur Bestimmung der Regressionskoeffizienten $\hat{\beta}$ wird eine Baseline aufgezeichnet, bei der der Proband angewiesen wird typische Augenbewegungen zu machen (Blinzeln, vertikale und horizontale Sakkaden und Rotieren der Augen), um eine gute Repräsentation der EOG-Aktivität zu erhalten. Gleichung 4.3 wird verwendet, um mit Hilfe der Baselinedaten die Regressionskoeffizienten zu bestimmen. Gleichung 4.2 kann anschließend sampleweise angewendet werden, um die EOG-Bereinigung in Echtzeit durchzuführen. Das beschriebene Verfahren wird zur online-Anwendung, wie der Spindel-detektor (s. Kapitel 2.1.2), in der Softwareumgebung RecView der Firma BrainProducts in C# implementiert. Die EOG-Bereinigung ist in dieser Umgebung ein Vorverarbeitungsschritt für den Spindel-detektor.

Evaluation

Für die Performanceanalyse des Verfahrens werden die EEG-Daten einer Fahr-simulatorstudie (N=28) verwendet, bei der es um die Auswirkung von visueller

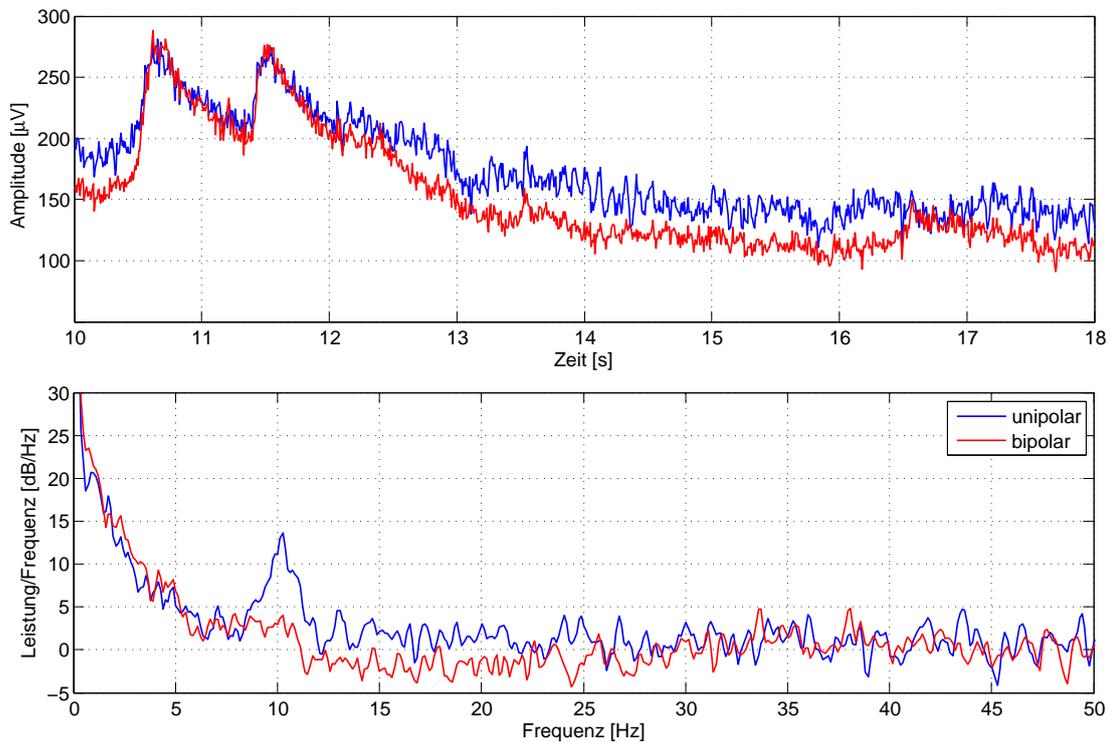


Abbildung 4.3: vertikales EOG: unipolare (Mastoid) vs. bipolare Referenzierung. Aufgenommen bei geschlossenen Augen. oben: Zeitverlauf des vertikalen EOGs mit Alpha-Aktivität zw. 13 s–16 s für unipolare und bipolare Referenzierung. unten: Welch-Periodogramm.

und akustischer Ablenkung beim Fahren auf verschiedene EEG-Parameter geht (Sonnleitner et al., 2012). Es wird ein EEG-System von BrainProducts mit 32 Elektroden verwendet (actiCap, BrainAmp-Verstärker). Die 32 Elektroden sind nach dem erweiterten 10-20 System positioniert mit Cz als Referenz. Vier Elektroden dienen zur EOG-Ableitung und sind wie in Abbildung 4.2 positioniert. Die Daten werden mit 250 Hz aufgezeichnet und anschließend zwischen 0,5–48 Hz Bandpass gefiltert und mit 128 Hz unterabgetastet.

Zur Bestimmung der Regressionskoeffizienten wird eine Baseline mit folgendem Ablauf aufgezeichnet:

- 20 s Blinzeln
- 5x Blick nach oben und unten
- 5x Blick nach links und rechts

- 5x Augen rollen

Abbildung 4.4 zeigt die Verteilung der mit Gleichung 4.3 bestimmten Regressionskoeffizienten $\hat{\beta}$, welche kanalweise über alle validen Datensätze (N=23) gemittelt sind. Das vertikale EOG hat die stärksten Einstreuungen an frontalen

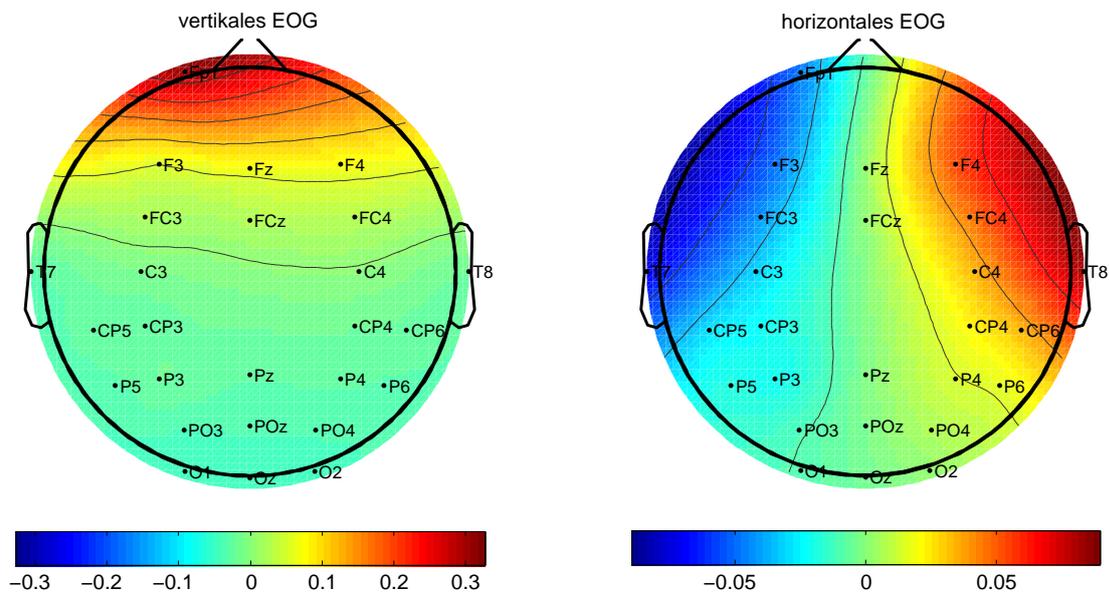


Abbildung 4.4: Topoplot der Regressionskoeffizienten des vertikalen und horizontalen EOGs. Dargestellt sind Mittelwerte von N=23 Datensätzen.

Elektroden und nimmt lateral-symmetrisch posterior kontinuierlich ab. Die negativen Koeffizienten an parietalen und okzipitalen Elektroden erklären sich durch die Referenzelektrode an Cz. Da an Cz ebenfalls Artefakte des vertikalen EOGs gemessen werden und diese größer als an posterioren Elektroden sind, wird der v-EOG Anteil bei der Differenzbildung im Verstärker negativ. Die Koeffizienten für das horizontale EOG zeigen eine umgekehrte Polarität auf den Hemisphären und Werte nahe Null am Scheitel, was durch die horizontale Rotation der Dipole in beiden Augen hervorgerufen wird.

Da Blinzeln die stärksten Artefakte hervorruft (s. Abbildung 4.4), wird zur Bewertung des Verfahrens die Reduktion der Blinzelamplitude kanalweise untersucht. Dazu werden Blinzler im v-EOG detektiert und anhand der maximalen Amplitude des Blinzlers zueinander ausgerichtet. In einem Intervall von -0,5–1 s um das Maximum werden alle Blinzler gemittelt, sowohl für das v-EOG wie auch die gleichen Datensegmente aller anderen EEG-Kanäle. In Abbildung 4.5 wird die

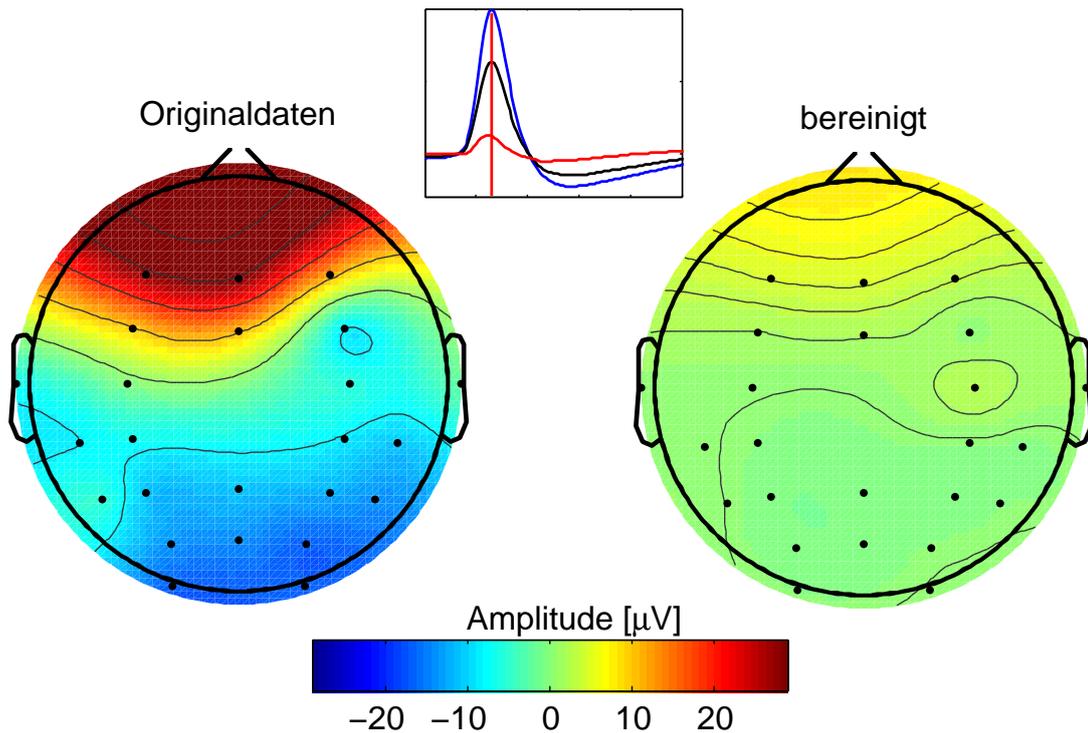


Abbildung 4.5: Topoplot der maximalen Blinzelamplitude vor und nach der Bereinigung mittels Regression. Dargestellt ist der Mittelwert über $N=23$ Datensätze. Die Grafik in der Mitte zeigt die gemittelten Blinzelamplituden des v-EOGs (blau) sowie eines EEG-Kanals vor (schwarz) und nach (rot) der Bereinigung.

Amplitude der EEG-Kanäle an der Stelle des v-EOG-Maximums vor der Bereinigung (links) und danach (rechts) in einem Topoplot aufgetragen. Zu erkennen ist eine deutliche Reduktion der EOG-spezifischen Amplituden an allen EEG-Kanälen. Nur frontal ist noch eine leichte EOG-Aktivität sichtbar.

Die Auswirkung der EOG-Bereinigung auf die Spektren der EEG-Kanäle ist ebenfalls von Interesse. Dazu wird das Welch-Periodogramm der Kanäle Fz, FCz, Pz und Oz vor und nach der Bereinigung für die gesamte Aufzeichnung berechnet. Anschließend werden die Spektren für jeden Probanden auf das spektrale Maximum des jeweils unbereinigten Kanals normiert und über alle Probanden gemittelt. Abbildung 4.6 zeigt links die resultierenden mittleren Spektren. Veränderungen zeigen sich für alle Kanäle primär bis ca. 5 Hz, der Bereich, in dem auch der größte Teil der EOG-Signaleriege konzentriert ist. Starke Änderungen in höheren Spektralbereichen wären hier unplausibel und ein Hinweis auf eine Überkompensation auf Grund von EEG-Anteilen im EOG-Signal. Gut zu erkennen ist außerdem

wie die Auswirkung der EOG-Bereinigung posterior abnimmt, was auf geringere Artefakteinstreuung in diesem Bereich zurückzuführen ist (vgl. Abbildung 4.4 links). Auf der rechten Seite in Abbildung 4.6 sind die mittleren Blinzelsamplituden dargestellt, welche analog zu Abbildung 4.5 berechnet werden. Die Daten werden hier auf das Maximum des v-EOG-Kanals normiert. Eine deutliche Reduktion der EOG-Amplitude ist erkennbar, wenn auch keine perfekte Bereinigung erzielt wird.

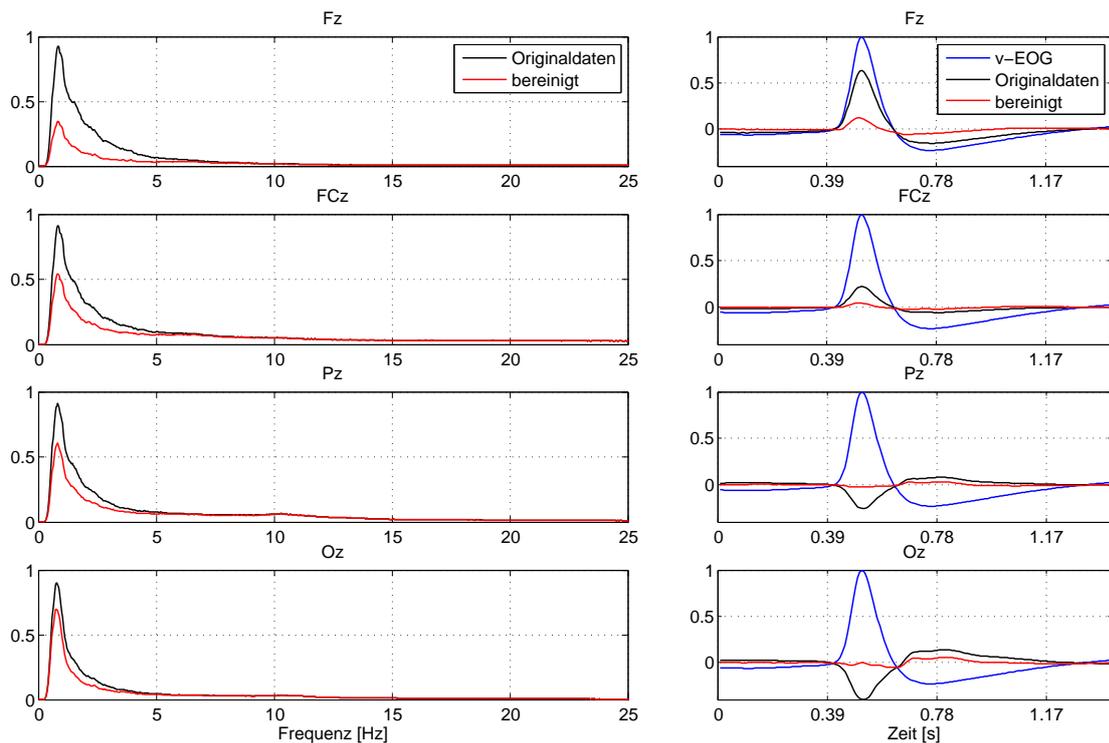


Abbildung 4.6: links: Einfluss der EOG-Bereinigung auf die Spektren ausgewählter Kanäle. Dargestellt ist der Mittelwert pro Frequenz der normierten Spektren über N=23 Probanden. rechts: Mittlere Blinzelsamplitude vor und nach der Bereinigung.

4.4 EMG-Artefaktdetektion

Die Behandlung von Muskelartefakten beschränkt sich in dieser Arbeit auf deren Detektion. Die Bereinigung durch oben beschriebenes Regressionsverfahren ist hier nicht möglich, da eine Vielzahl von Muskeln zu den Artefakten beitragen und nicht alle mit separaten Elektroden erfasst werden können.

Das Verfahren zur Detektion von Muskelartefakten sollte für die Anwendung in Echtzeit geeignet sein und dabei separat für jeden Kanal arbeiten sowie eine hohe zeitliche Auflösung bieten. Durch die Beseitigung von Segmenten mit Artefaktkontamination soll die Robustheit und Validität der Echtzeit-Spindeldekton sowie aller nachfolgenden Analyseschritte erhöht werden. Wie in der Einleitung beschrieben haben EMG-Artefakte massive Auswirkungen auf nahezu alle Frequenzbänder und müssen dementsprechend bei der Auswertung berücksichtigt werden. In einer Metaanalyse von [Fatourechhi et al. \(2007\)](#), welche die Artefaktbehandlung bei BCI-Studien analysiert, verwenden nur 3,2% der untersuchten Studien eine automatisierte Routine zur Muskelartefakterkennung. Gerade im BCI-Umfeld ist eine Echtzeitverarbeitung von EEG-Daten gängig und eine automatisierte online-Erkennung von Muskelartefakten von Vorteil, aber nach wie vor kein fester Bestandteil in der Verarbeitungskette.

Prinzipiell sind die in Abschnitt 4.1 beschriebenen Ansätze für trial-basierte EEG-Daten auch in einem online-Setting anwendbar ([van de Velde et al., 1998](#); [Delorme et al., 2007](#)), allerdings wird dies in den genannten Studien nicht explizit analysiert. Hier wird die Leistung in einem Frequenzband (> 20 Hz) mit einer Baselinemessung verglichen. Bei überschreiten eines gewissen Schwellwertes, wird das Segment als Artefakt eingestuft. Bei [van de Velde et al. \(1998\)](#) werden auch mit dem Steigungsparameter der Zeitreihe (erste Ableitung) Muskelartefakte erkannt.

Erste Ansätze zur online-Detektion von Artefakten basieren ebenfalls auf dem Vergleich der Leistung eines spektralen Bandes (34–44 Hz bzw. 25–31 Hz) mit einer Baselinemessung ([Gevins et al., 1977](#); [Pfurtscheller et al., 1996](#)), allerdings nur mit einer mäßigen Performance (TPR: 65%, FPR: 44%). Die Zeitauflösung ist auf 1 s begrenzt und es wird keine individuelle Entscheidung pro Kanal getroffen, sodass die Daten aller Kanäle in einem Artefaktsegment verloren gehen. Dies stellt einen unnötigen Verlust an Daten dar, da bekannt ist, dass sich Muskelaktivität, abhängig von der Entfernung zum Muskel, verschieden stark an unterschiedlichen Elektrodenpositionen auswirkt ([Goncharova et al., 2003](#)) und deshalb nicht alle

Kanäle unbrauchbar sein müssen.

Ein anderer Ansatz beruht auf der Beschreibung des EEGs mit einem parametrischen Modell. Das Auftreten eines Artefaktes führt entweder zu signifikanten Änderungen der Modellparameter oder zu einer signifikanten Erhöhung des Modellfehlers, da das Artefakt mit dem vorhandenen Modell nicht adäquat beschrieben werden kann. Für die online-Detektion von Artefakten haben sich vor allem *autoregressive Modelle* (AR-Modelle) etabliert. In einem Paper von [van de Velde et al. \(1999\)](#) wird ein separates AR-Modell der Ordnung fünf für jedes 1 s EEG-Segment geschätzt und ein Vektor aus den jeweiligen AR-Koeffizienten und dem mittleren Fehler gebildet. Anschließend wird die Varianz mehrerer solcher Modellvektoren über einen Zeitraum von 20 s ermittelt. Für ein direkt im Anschluss folgendes 10 s Testfenster wird ebenfalls eine solche Varianz bestimmt. Beide Varianzen werden mit einem F-Test auf Gleichheit überprüft. Bei Ablehnung der Nullhypothese wird das Testfenster als Artefakt klassifiziert. Die Performance des Verfahrens wird von den Autoren allerdings als unzureichend eingeschätzt, da lang andauernde Artefakte mit dieser Methode nicht mehr erkannt werden können. Grund hierfür ist die allmähliche Erhöhung der Varianz in Referenz- und Testfenster. Hinzu kommt eine relativ grobe Zeitauflösung von 10 s.

[Schlögl \(2000\)](#) hat in seiner Arbeit ein zeitvariables AR-Modell der Ordnung 10 verwendet, bei dem die AR-Koeffizienten mit Hilfe eines Kalman-Filters über die Zeit getrackt werden und sich das Modell somit an veränderte statistische Eigenschaften der Zeitreihe anpassen kann. Die Annahme ist, dass transiente Ereignisse, wie z.B. Artefakte, durch die Trägheit des Kalman-Filters nicht korrekt getrackt werden können, was zu einer Erhöhung des Modellfehlers führt. Der Modellfehler zu einem Zeitpunkt dient damit als Indikator für das Vorhandensein eines Artefaktes. Die Methode arbeitet sampleweise und separat für jeden Kanal. Es werden AUC-Werte von 0,86 für die Detektion von Muskelartefakten erzielt, wobei auch andere Typen von Störungen damit erkannt werden können.

Im Folgenden soll die Verwendung von autoregressiven Modellen für die Identifikation von Artefakten genauer untersucht werden. Insbesondere soll die Performance eines zeitinvarianten AR-Modells mit konstanten Koeffizienten mit einem zeitvariablen AR-Modell verglichen werden. Kapitel [4.4.1](#) und [4.4.2](#) erläutern die Theorie der beiden Modelle und in Kapitel [4.4.3](#) werden die Ergebnisse für beide Modelle beschrieben und diskutiert.

4.4.1 Stationäre autoregressive Modelle

Autoregressive Modelle bilden diskrete, stationäre, stochastische Prozesse durch eine lineare Differenzgleichung mit konstanten Koeffizienten ab (Brockwell und Davis, 2006). Eine große Klasse stationärer Prozesse kann mit Hilfe autoregressiver Modelle (AR) und deren Erweiterungen (ARMA, ARIMA) beschrieben werden. EEG-Daten lassen sich ebenfalls mit AR-Modellen effizient darstellen (z.B. Gersch, 1970).

In einem AR-Modell wird eine Reihe von zufälligen Anregungen („Shocks“) auf einen linearen Filter angewendet (s. Abbildung 4.7), der als Ausgang die beobachtete Zeitreihe mit zeitlich korrelierten Elementen liefert (Haykin, 1986). Die



Abbildung 4.7: Stochastisches Modell eines AR-Prozesses.

Shocks sind unabhängig und entstammen einer Normalverteilung mit Erwartungswert Null und Varianz σ_v^2 (weißes Rauschen). Ein autoregressiver Prozess $u(n)$ der Ordnung M (AR(M)) kann durch folgende Differenzgleichung beschrieben werden:

$$u(n) + a_1 u(n-1) + a_2 u(n-2) + \dots + a_M u(n-M) = v(n), \quad (4.4)$$

mit $v(n) \sim \mathcal{N}(0, \sigma_v^2)$ (Haykin, 1986). Weiter bezeichnen a_1, a_2, \dots, a_M die Parameter des AR-Prozesses und $v(n)$ das weiße Rauschen. Gleichung 4.4 beinhaltet keinen konstanten Term, da für den autoregressiven Prozess vorausgesetzt wird, dass $E[u(n)] = 0$. Der Begriff „autoregressiv“ basiert auf der Tatsache, dass sich die aktuelle Beobachtung $u(n)$ der Zeitreihe aus der gewichteten Summe vergangener Beobachtungen ergibt; analog einer linearen Regression mit $u(n-1), \dots, u(n-M)$ als Regressoren und $v(n)$ als Fehlerterm der Regression. Umstellen von Gleichung 4.4 verdeutlicht dies:

$$\begin{aligned} u(n) &= -a_1 u(n-1) - a_2 u(n-2) - \dots - a_M u(n-M) + v(n) \\ &= \sum_{k=1}^M -a_k u(n-k) + v(n). \end{aligned} \quad (4.5)$$

Gleichung 4.5 kann auch folgendermaßen interpretiert werden (s. Abbildung 4.7):

Die Beobachtung $u(n)$ ist das Ergebnis eines linearen Filters, welcher mit weißem Rauschen $v(n)$ angeregt wird (Gersch, 1970). Die AR-Parameter a_1, a_2, \dots, a_M stellen dabei die Koeffizienten des Filters dar.

Im Folgenden bezeichnen $U(z)$, $V(z)$ und $A(z)$ die z-Transformationen der Folgen $u(n)$, $v(n)$ respektive a_n . Berücksichtigt man, dass die linke Seite von Gleichung 4.4 eine Faltung darstellt, ergibt sich die z-Transformation der Gleichung zu (Haykin, 1986)

$$A(z)U(z) = V(z).$$

Die Übertragungsfunktion $H_G(z)$ mit $U(z)$ als Ausgang und $V(z)$ als Eingang eines Filters lautet dann

$$\begin{aligned} H_G(z) &= \frac{U(z)}{V(z)} \\ &= \frac{1}{A(z)} \\ &= \frac{1}{1 + \sum_{n=1}^M a_n z^{-n}}. \end{aligned} \tag{4.6}$$

Das AR-Modell ist stabil, wenn ein beschränktes Eingangssignal auch ein beschränktes Ausgangssignal zur Folge hat – eine Bedingung, die in der praktischen Anwendung immer erfüllt sein muss. Die Stabilität ist gegeben, wenn alle Polstellen der Übertragungsfunktion 4.6 innerhalb des Einheitskreises der z-Ebene liegen (Haykin, 1986).

Ein AR-Modell kann auch zur parametrischen Beschreibung der spektralen Leistungsdichte (power spectral density, PSD) einer Zeitreihe verwendet werden. Die PSD $S_o(\omega)$ am Ausgang eines linearen zeitinvarianten Filters ist gegeben durch (Haykin, 1986)

$$S_o(\omega) = |H_G(e^{j\omega})|^2 S(\omega).$$

$H_G(e^{j\omega})$ entspricht der Übertragungsfunktion $H_G(z)$ ausgewertet auf dem Einheitskreis (d.h. $|z| = r = 1$) und $S(\omega)$ ist die PSD des Eingangssignals. Man beachte, dass die Fourier- und z-Transformationen über $z = re^{j\omega}$ folgendermaßen zusammenhängen (Oppenheim und Schaffer, 1989):

$$\mathcal{Z}[x(n)] = \mathcal{F}[r^{-n}x(n)].$$

Mit $\mathcal{F}[v(n)] = S(\omega) = \sigma_v^2$ (weißes Rauschen) ergibt sich $S_o(\omega)$ zu

$$\begin{aligned} S_o(\omega) &= \left| H_G(e^{j\omega}) \right|^2 \sigma_v^2 \\ &= \frac{\sigma_v^2}{\left| 1 + \sum_{m=1}^M a_m e^{-jm\omega} \right|^2}. \end{aligned} \quad (4.7)$$

Für die Schätzung der unbekannt Parameter a_1, \dots, a_M ist es hilfreich, Gleichung 4.5 in Matrix-Schreibweise auszudrücken:

$$u(n) = \mathbf{u}(n-1)\mathbf{a} + v(n) \quad (4.8)$$

mit $\mathbf{u}(n-1) = [-u(n-1), \dots, -u(n-M)]$ und $\mathbf{a} = [a_1, \dots, a_M]^T$. In Gleichung 4.8 wird also $u(n)$ durch die vorangegangenen Werte $\mathbf{u}(n-1)$ geschätzt, was auch als *one-step prediction* oder *forward-prediction* bezeichnet wird. Setzt man in Gleichung 4.8 für die wahren AR-Parameter deren Schätzer $\hat{\mathbf{a}}$ ein, so erhält man

$$\hat{u}(n) = \mathbf{u}(n-1)\hat{\mathbf{a}}.$$

Ziel ist es nun, einen Parametervektor $\hat{\mathbf{a}}$ zu bestimmen, der den Modellfehler $\hat{v}(n)$ (*one-step prediction error*), gegeben durch

$$\hat{v}(n) = u(n) - \hat{u}(n), \quad (4.9)$$

minimiert. Dies kann z.B. durch die Methode der kleinsten Quadrate erfolgen. Obwohl andere Ansätze zur Bestimmung der Parameter existieren (z.B. Minimierung des forward-backward prediction error, Yule-Walker Gleichungen), ist der one-step prediction error hier naheliegend, da er später auch zur Detektion von Artefakten, d.h. nicht modellkonformen Zeitsegmenten verwendet wird.

Die unbekannt Fehlervarianz σ_v^2 des AR-Modells lässt sich aus der Varianz des one-step prediction errors ermitteln:

$$\hat{\sigma}_v^2 = \frac{1}{N-M} \sum_{n=M+1}^N \hat{v}(n)^2, \quad (4.10)$$

wobei N die Länge der Zeitreihe ist (Xie und Ljung, 2004).

Analog zu den normierten Innovationen des Kalman-Filters (s. Gleichung 4.26)

kann der Modellfehler $e(n)$ normiert werden zu

$$\epsilon_v(n) = \frac{\hat{v}(n)^2}{\hat{\sigma}_v^2}, \quad (4.11)$$

sodass $\epsilon_v(n)$ einer χ^2 -Verteilung folgt. Eine genauere Beschreibung dieses Ansatzes findet sich im folgenden Abschnitt.

4.4.2 Zeitvariable autoregressive Modelle

Ein zeitvariables, autoregressives Modell der Ordnung M wird analog zu Gleichung 4.4 durch folgende Differenzengleichung beschrieben:

$$u(n) + a_1(n)u(n-1) + a_2(n)u(n-2) + \dots + a_M(n)u(n-M) = v(n).$$

Im Unterschied zum stationären AR-Modell sind die Parameter nicht konstant, sondern können im Zeitverlauf variieren. Dieser Abschnitt erläutert, wie ein zeitvariables AR-Modell in die Systematik der Zustandsraummodelle überführt werden kann, was die rekursive Schätzung der AR-Parameter durch den Kalman-Filter ermöglicht. Damit ist es möglich, das Modell auf Nicht-Stationaritäten der Zeitreihe zu adaptieren. Da EEG-Zeitreihen nicht stationär sind, sollte auf diese Weise eine bessere Adaption des Modells an die Daten erreicht werden. Die rekursive Parameterschätzung mit dem Kalman-Filter ermöglicht darüber hinaus die Anwendung der Methode in Echtzeitsystemen.

Zustandsraummodell

Das Zustandsraummodell (state space model) drückt den Zustand eines Systems aus, welcher die minimale Menge an Informationen aus Vergangenheit und Gegenwart enthält, um damit zukünftiges Systemverhalten zu beschreiben (Rinne und Specht, 2002). Die folgenden Definitionen orientieren sich an den Notationen aus Bar-Shalom et al. (2001) und Haykin (1986). Das Zustandsraummodell besteht aus zwei Gleichungen, der *Systemgleichung*

$$\mathbf{x}(n+1) = \mathbf{F}(n)\mathbf{x}(n) + \mathbf{w}(n) \quad (4.12)$$

und der *Messgleichung*

$$\mathbf{z}(n) = \mathbf{H}(n)\mathbf{x}(n) + \mathbf{v}(n). \quad (4.13)$$

Gleichung 4.12 enthält latente Systemvariablen $\mathbf{x}(n)$, welche nicht direkt beobachtet werden können und die es zu schätzen gilt. Der Übergang des Systems von n zu $n+1$ wird mit der Matrix $\mathbf{F}(n)$ beschrieben. Das Prozessrauschen $\mathbf{w}(n)$ ist normalverteilt mit Erwartungswert Null und Kovarianzmatrix \mathbf{Q}_n , d.h. $\mathbf{w}(n) \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_n)$ und ist zeitlich unkorreliert (weißes Rauschen). Die messbaren Variablen sind in $\mathbf{z}(n)$ zusammengefasst und $\mathbf{H}(n)$ definiert, wie die Messgrößen aus den latenten Variablen hervorgehen. Dabei ist $\mathbf{v}(n)$ das Messrauschen mit $\mathbf{v}(n) \sim \mathcal{N}(\mathbf{0}, \mathbf{R}_n)$. Die Störgrößen $\mathbf{w}(n)$ und $\mathbf{v}(n)$ werden als unabhängig angenommen.

In der allgemeinen Definition von Gleichung 4.12 sind zusätzlich bekannte externe Eingangssignale möglich (Bar-Shalom et al., 2001), welche hier ignoriert werden, da sie für die Modellierung von Zeitreihen eine untergeordnete Rolle spielen. Die Systemgleichung 4.12 erfüllt die Markov-Eigenschaft (Rinne und Specht, 2002), die besagt, dass der Folgezustand $x(n+1)$ nur vom vorherigen Zustand $x(n)$ abhängt, d.h. $x(n)$ enthält alle Informationen um $x(n+1)$ zu beschreiben. Wenn die Matrizen $\mathbf{F}(n)$ und $\mathbf{H}(n)$ konstant sind, dann beschreiben Gleichung 4.12 und 4.13 ein zeitinvariantes (stationäres) System.

Für die Übertragung des zeitvariablen AR-Modells in das Zustandsraummodell werden die unbekanntenen AR-Parameter $\mathbf{a}(n)$ als die latenten Variablen $\mathbf{x}(n)$ angesehen. Um die zeitlich veränderlichen AR-Parameter zu modellieren, wird für die Systemgleichung ein Random-Walk angenommen:

$$\mathbf{a}(n+1) = \mathbf{a}(n) + \mathbf{w}(n), \quad (4.14)$$

mit $\mathbf{a}(n) = (a_1(n), \dots, a_M(n))'$ und $\mathbf{w}(n)$ als $(M \times 1)$ Rauschvektor mit konstanter Kovarianzmatrix $\sigma_w^2 \mathbf{I}$ (Haykin, 1986). Die Matrix $\mathbf{F}(n)$ reduziert sich auf eine Einheitsmatrix $\mathbf{I} \in \mathbb{R}^{M \times M}$. Die Messgleichung ergibt sich zu

$$u(n) = \mathbf{H}(n)\mathbf{a}(n) + v(n), \quad (4.15)$$

mit dem Skalar $u(n)$ als aktuelle Beobachtung. Die $(1 \times M)$ Matrix $\mathbf{H}(n)$ beinhaltet die vergangenen Beobachtungen der Zeitreihe, d.h. $\mathbf{H}(n) = \mathbf{u}(n-1)$ aus Gleichung 4.8. Der skalare Fehlerterm $v(n)$ entspricht den Shocks aus Gleichung 4.4 und hat die konstante Varianz σ_v^2 .

Kalman-Filter

Der Kalman-Filter beinhaltet ein Set von Gleichungen, welche eine rekursive Schätzung des *Minimum Mean Square Error Estimators* (MMSE) darstellen (Bar-Shalom et al., 2001). Der MMSE von unbekanntem Parameter x , gegeben den Messungen z , ist ein Bayes Schätzer (unbekannte Parameter sind nicht deterministisch, sondern ebenfalls Zufallsvariablen) und gegeben durch den bedingten Erwartungswert einer a-posteriori Verteilung:

$$MMSE = \hat{x}(z) = E[x|z] = \int xp(x|z)dx.$$

Sind x und z normalverteilt, ist der MMSE Schätzer identisch dem *Maximum A-Posteriori* Schätzer (MAP) der Bayesschen Inferenz, da bei einer Normalverteilung der Erwartungswert und die Mode (Maximum) zusammenfallen. Dann ergibt sich $E[x|z]$ zu (Bar-Shalom et al., 2001)

$$\hat{x} = E[x|z] = \bar{x} + P_{xz}P_{zz}^{-1}(z - \bar{z}) \quad (4.16)$$

und für dessen Kovarianz

$$P_{xx|z} = E[(x - \hat{x})(x - \hat{x})'|z] = P_{xx} - P_{xz}P_{zz}^{-1}P_{zx}. \quad (4.17)$$

Gleichungen 4.16 und 4.17 sind Ausgangspunkt für die Entwicklung der Kalman-Filter Gleichungen, wobei der bedingte Erwartungswert für die latenten Variablen der Systemgleichung definiert ist als

$$\hat{\mathbf{x}}(n|n) = E[\mathbf{x}(n)|Z^n],$$

mit Z^n als Sequenz der vergangenen Beobachtungen $\mathbf{z}(i)$, mit $(i \leq n)$.

Die rekursiven Gleichungen des Kalman-Filters lassen sich in zwei Hauptschritte unterteilen (Bar-Shalom et al., 2001). Im **Prädiktionsschritt** werden Vorhersagen für die latenten Variablen und die Beobachtungen sowie deren Kovarianzen

anhand der aktuell zur Verfügung stehenden Information gemacht:

$$\hat{\mathbf{x}}(n+1|n) = \mathbf{F}(n)\hat{\mathbf{x}}(n|n) \quad (4.18)$$

$$\mathbf{P}(n+1|n) = \mathbf{F}(n)\mathbf{P}(n|n)\mathbf{F}(n)' + \mathbf{Q}_n \quad (4.19)$$

$$\hat{\mathbf{z}}(n+1|n) = \mathbf{H}(n+1)\hat{\mathbf{x}}(n+1|n) \quad (4.20)$$

$$\mathbf{S}(n+1) = \mathbf{H}(n+1)\mathbf{P}(n+1|n)\mathbf{H}(n+1)' + \mathbf{R}_{n+1} \quad (4.21)$$

Gleichung 4.18 beinhaltet den prädizierten Zustand und 4.19 die zugehörige prädizierte Kovarianz. In 4.20 werden die Beobachtungen $\hat{\mathbf{z}}(n+1|n)$ anhand des Zustandsvektors $\hat{\mathbf{x}}(n+1|n)$ geschätzt (one-step prediction), wobei $\mathbf{S}(n+1)$ in 4.21 die Kovarianzmatrix von $\hat{\mathbf{z}}(n+1|n)$ ist.

Im **Updateschritt** wird schließlich der bedingte Erwartungswert von $\hat{\mathbf{x}}$ und die zugehörige Kovarianzmatrix bestimmt:

$$\hat{\mathbf{x}}(n+1|n+1) = \hat{\mathbf{x}}(n+1|n) + \mathbf{W}(n+1)\boldsymbol{\nu}(n+1) \quad (4.22)$$

$$\mathbf{W}(n+1) = \mathbf{P}(n+1|n)\mathbf{H}(n+1)'\mathbf{S}(n+1)^{-1} \quad (4.23)$$

$$\boldsymbol{\nu}(n+1) = \mathbf{z}(n+1) - \hat{\mathbf{z}}(n+1|n) \quad (4.24)$$

$$\mathbf{P}(n+1|n+1) = \mathbf{P}(n+1|n) - \mathbf{W}(n+1)\mathbf{H}(n+1)\mathbf{P}(n+1|n) \quad (4.25)$$

Gleichungen 4.22 und 4.25 sind die rekursiven Umsetzungen von 4.16 und 4.17 für das Zustandsraummodell. Sie geben, unter Berücksichtigung der neuesten Beobachtung $\mathbf{z}(n+1)$, die Schätzung des aktuellen Zustands sowie dessen Kovarianz an. Die Matrix $\mathbf{W}(n+1)$ in (4.23) wird auch als **Kalman-Verstärkung** bezeichnet. Der Vektor der **Innovationen** $\boldsymbol{\nu}(n+1)$ in (4.24) ist der Vorhersagefehler des Modells und ein Maß für den neuen Informationsgehalt in $\mathbf{z}(n+1)$ (Haykin, 1986). Außerdem ist der Innovationsvektor ein Maß für die Modellanpassung. Große Innovationswerte weisen darauf hin, dass das Modell (die latenten Variablen) nicht zu den aktuellen Beobachtungen passen.

Damit der Kalman-Filter optimal arbeitet, muss er konsistent sein, d.h. die theoretischen Annahmen der Schätzfehler müssen erfüllt sein (Bar-Shalom et al., 2001). Dazu zählt, dass der Fehler den Erwartungswert Null haben muss und eine Kovarianz, wie sie vom Filter bestimmt wurde. Für einen Filter in der praktischen Anwendung lassen sich nur die Fehler bei der Vorhersage der Beobachtungen, die Innovationen $\boldsymbol{\nu}(n)$, auf Konsistenz überprüfen. Die Fehler bei der Schätzung der latenten Variablen lassen sich nur in Simulationen bestimmen. Mit Hilfe der

normierten Innovationen (normalized innovations squared, NIS) lassen sich beide Konsistenzkriterien überprüfen (Bar-Shalom et al., 2001):

$$\boldsymbol{\epsilon}_\nu(n) = \boldsymbol{\nu}(n)' \mathbf{S}(n)^{-1} \boldsymbol{\nu}(n). \quad (4.26)$$

Unter der Nullhypothese, dass der Filter konsistent ist, folgt $\boldsymbol{\epsilon}_\nu(n)$ einer χ^2 -Verteilung mit n_z Freiheitsgraden, wobei n_z die Größe des Beobachtungsvektors $\mathbf{z}(n)$ ist. Um die Variabilität der Teststatistik zu reduzieren, kann $\boldsymbol{\epsilon}_\nu(n)$ in einem gleitenden Fenster der Länge L aufsummiert werden:

$$\bar{\boldsymbol{\epsilon}}_\nu(n) = \sum_{k=n-L}^n \boldsymbol{\nu}(k)' \mathbf{S}(k)^{-1} \boldsymbol{\nu}(k). \quad (4.27)$$

Unter der Nullhypothese ist $\bar{\boldsymbol{\epsilon}}_\nu(n)$ wieder χ^2 -verteilt, allerdings mit Ln_z Freiheitsgraden. In dieser Arbeit wird ein Fenster der Länge $L = 50$ verwendet, was bei 125 Hz Abtastrate 0,4 s Dauer entspricht. Mit Gleichung 4.27 kann ein Konsistenzcheck des Kalman-Filters während der Laufzeit durchgeführt werden. Als normiertes Fehlermaß kann die Wahrscheinlichkeit $F_X(\bar{\boldsymbol{\epsilon}}_\nu(n); Ln_z) = P(X \leq \bar{\boldsymbol{\epsilon}}_\nu(n))$ verwendet werden. $F_X(\cdot; Ln_z)$ ist die Verteilungsfunktion der χ^2 -Verteilung mit Ln_z Freiheitsgraden.

Formulierung des zeitvariablen AR-Modells im Kalman-Filter

Bei der Überführung des zeitvariablen AR-Modells in die Systematik des Kalman-Filters ergeben sich einige Vereinfachungen in den Prädiktions- und Updategleichungen, da z.B. $\mathbf{z}(n)$ skalar und $\mathbf{F}(n)$ die Einheitsmatrix ist. Tabelle 4.1 gibt einen Überblick der korrespondierenden Notationen sowie die zugehörigen Dimensionen der Variablen. Gleichung 4.18 ist damit trivial und kann weggelassen werden und Gleichung 4.19 reduziert sich zu

$$\mathbf{P}(n+1|n) = \mathbf{P}(n|n) + \mathbf{Q}_n.$$

Der Kalman-Filter muss mit Startwerten für $\hat{\mathbf{x}}(0|0)$ und $\mathbf{P}(0|0)$ initialisiert werden. Im Folgenden wird $\hat{\mathbf{x}}(0|0) = \mathbf{0}$ und $\mathbf{P}(0|0) = 0.1 * \mathbf{I}$ gesetzt. Die Varianz σ_w^2 des Prozessrauschens muss ebenfalls bekannt sein. Da diese Größe empirisch nicht zugänglich ist, wird σ_w^2 hinsichtlich der Artefaktdetektion optimiert. Eben-

Kalman-Notation	AR-Notation	Dimension
$\hat{\mathbf{x}}(n n)$	$\hat{\mathbf{a}}(n)$	$M \times 1$
$\mathbf{F}(n)$	\mathbf{I}	$M \times M$
\mathbf{Q}_n	$\sigma_w^2 \mathbf{I}$	$M \times M$
$\hat{\mathbf{z}}(n n)$	$\hat{u}(n)$	1×1
$\mathbf{H}(n)$	$\mathbf{u}(n-1)$	$1 \times M$
\mathbf{R}_n	σ_v^2	1×1

Tabelle 4.1: Überführung der Zustandsraumgleichungen des AR(M)-Modells (4.14 und 4.15) in die Kalman-Filter Gleichungen.

so wird die Modellordnung M so gewählt, dass sie bestmögliche Performance bei der Artefaktdetektion liefert. Die Resultate sind in Kapitel 4.4.3 beschrieben. Die Varianz des Messrauschens σ_v^2 lässt sich folgendermaßen bestimmen: In einer Baselinemessung von ca. 30 s, in der störungsfreie EEG-Daten aufgezeichnet werden, wird ein zeitinvariantes AR-Modell 4.5 an die Daten adaptiert. Mit Hilfe von Gleichung 4.10 kann die Fehlervarianz des AR-Modells bestimmt werden, welche dem Messrauschen des Kalman-Filters entspricht. Alternativ kann, unter der Annahme eines nicht-stationären Messrauschens, σ_v^2 auch zeitvariabel definiert werden und aus den aktuellen Messungen rekursiv ermittelt werden. Dies kann z.B. mit einem Exponentialfilter geschehen:

$$\sigma_v^2(n) = (1 - \mu)\nu^2 + \mu\sigma_v^2(n-1), \quad (4.28)$$

mit $\sigma_v^2(0) = 1$ (Schack et al., 1995). Der Parameter μ wird ebenfalls hinsichtlich der Artefaktdetektion optimiert (s. Kapitel 4.4.3). Bei der zeitvariablen Schätzung von σ_v^2 muss keine Baselinemessung mehr erfolgen. Beide Varianten des Kalman-Filters werden hinsichtlich ihrer Eignung für die Artefaktdetektion in Kapitel Kapitel 4.4.3 miteinander verglichen.

Artefaktdetektion

Um stationäre AR-Modelle für die online Artefakterkennung zu verwenden, müssen die unbekanntenen AR-Parameter in einer repräsentativen Baseline geschätzt werden. Dazu wird vor dem Experiment 30 s Ruhe-EEG aufgezeichnet, bei dem keine Artefakte auftreten dürfen. Für eine gute Modellierung der Alpha-Spindeln, kann ein weiterer 30 s Abschnitt mit geschlossenen Augen aufgezeichnet werden. Die gleiche Baseline wird verwendet, um die Varianz des Messrauschens mit Hilfe

von Gleichung 4.10 für den Kalman-Filter zu bestimmen.

Für die Detektion von Artefakten mit dem stationären AR-Modell wird angenommen, dass das aus der Baseline ermittelte AR-Modell die u.U. nicht-stationäre EEG-Zeitreihe hinreichend gut approximiert, d.h. geringe Wahrscheinlichkeiten des normierten Modellfehlers 4.11 in der Verteilungsfunktion der χ^2 -Verteilung erzielt. Weiterhin wird angenommen, dass Artefakte nicht korrekt modelliert werden können und somit einen deutlich höheren Modellfehler respektive eine größere Fehlerwahrscheinlichkeit als das Normal-EEG aufweisen.

Für das zeitvariable AR-Modell wird angenommen, dass trotz der adaptierbaren AR-Parameter für Artefakte kein konsistenter Filter gefunden werden kann, da Artefakte mit einem AR-Modell nicht, oder nur sehr schlecht, abgebildet werden können. Dies hat zur Folge, dass auch hier die Wahrscheinlichkeiten der normierten Innovationen im Vergleich zum störungsfreien EEG sehr groß sind und eine Detektion von Artefakten ermöglicht wird.

Der Verlust an Daten – da detektierte Segmente nicht mehr zur Weiterverarbeitung zur Verfügung stehen – ist bei den Studien zu Müdigkeit im Allgemeinen vertretbar. Typischerweise liegen mehrstündige Aufzeichnungen vor und kürzere nicht verwertbare Abschnitte beeinträchtigen die Qualität der Analysen nur unwesentlich.

4.4.3 Ergebnisse

Da kein Referenzsystem zur Artefaktdetektion zur Verfügung steht, ist es für die Evaluation der Algorithmen notwendig EEG-Daten von erfahrenen Experten manuell in artefaktbehaftete und artefaktfreie Abschnitte klassifizieren zu lassen. Es wird im Folgenden auf eine Studie über Workload-Klassifikation im Fahrzeug zurückgegriffen (Dixon et al., 2009). In dieser Studie sind Segmente mit Artefakten manuell markiert, jedoch wird keine kanalweise Klassifikation vorgenommen, d.h. es sind primär Abschnitte markiert, in denen die Mehrzahl von Kanälen Störungen aufweist. Eine kanalweise Markierung der Artefakte wäre für die zu untersuchenden Algorithmen von Vorteil, um die Performance exakt bestimmen zu können, allerdings ist mit den vorliegenden Referenzdaten der relative Vergleich der vorgestellten Ansätze gut möglich. Auch können die optimalen Parameter der Algorithmen mit den gelabelten Daten festgelegt werden. Nach erneuter Inspektion der gelabelten Abschnitte, stellt sich heraus, dass in einem Artefaktabschnitt meist die Mehrzahl der Kanäle betroffen ist. Da Artefakte, die nur an einzelnen Kanälen

auftreten nicht gelabelt werden, können die unmarkierten Abschnitte per se nicht als artefaktfreie Daten angesehen werden. Stattdessen werden zusätzlich, auf allen Kanälen artefaktfreie Segmente markiert und für die weitere Analyse verwendet.

Es stehen 19 Datensätze von jeweils ca. einer Stunde Dauer zur Verfügung. Das EEG wird mit 30 Kanälen nach dem erweiterten internationalen 10-20 System mit einer BrainProducts BrainCap und BrainAmp-Verstärker aufgezeichnet. Alle Elektroden werden unipolar gegen FCz abgeleitet und mit 500 Hz abgetastet. Vor der Weiterverarbeitung werden die Daten zwischen 0,5 Hz und 62,5 Hz Bandpass gefiltert und anschließend auf 125 Hz unterabgetastet. Von den 30 EEG-Kanälen werden 11 zur Evaluation der Algorithmen ausgewählt. Dies sind F3, Fz, F4, C3, Cz, C4, P3, Pz, P4, O1 und O2. Vor der Artefaktdetektion werden die EEG-Kanäle mit dem in Kapitel 4.3 beschriebenen Regressionsverfahren von EOG-Artefakten bereinigt.

Insgesamt sind 5017s als Artefakte und 5440s als artefaktfreie Segmente markiert. Nicht alle artefaktfreien Datenabschnitte eines Datensatzes werden zur Analyse verwendet, sondern es wird eine zufällige Stichprobe ausgewählt, welche gleichmäßig über den gesamten Datensatz verteilt ist. Durch die daraus resultierende nahezu identische Stichprobengröße für artefaktfreie und artefaktbehaftete Daten ist eine ausgeglichene Gewichtung beider Klassen in der Analyse gewährleistet. Weiterhin ist eine Auswertung der gesamten artefaktfreien Daten durch die hohe Rechenzeit der Analysen nicht möglich. Es sind 6,5% der gesamten Daten mit Artefakten kontaminiert. Die mittlere Länge markierter Artefakte liegt bei 2s und für artefaktfreie Abschnitte bei 2,5s. Da im geschilderten Experiment keine Baseline zur Adaption des AR-Modells aufgezeichnet wird, dienen die ersten 25s der artefaktfreien Segmente als Baseline. Diese Baseline wird bei der Performanceanalyse der Algorithmen nicht verwendet.

Für mehrere freie Parameter der Algorithmen sind die optimalen Werte nicht bekannt und müssen anhand der vorliegenden Daten ermittelt werden. Dazu werden verschiedene Parameterwerte getestet und das Optimum hinsichtlich der Diskrimination von Artefakten ausgewählt. Ein freier Parameter für stationäre und zeitvariable AR-Modelle ist dessen Ordnung M , welcher im Bereich von 5 bis 20 variiert wird. Für den Kalman-Filter muss zusätzlich das Prozessrauschen σ_w^2 festgelegt werden. Werte von 10^{-3} , 10^{-4} und 10^{-5} werden untersucht. Das Messrauschen σ_v^2 kann zwar anhand der Baseline bestimmt werden, allerdings werden zusätzlich skalierte Versionen dieses Wertes hinsichtlich ihrer Eignung untersucht ($\sigma_{vs}^2 = s\sigma_v^2$, mit Skalierungsfaktor $s = [1; 1,5; 2; 2,5; 3; 4; 5]$). Für das stationäre

AR-Modell hat das Messrauschen nur Einfluss auf den normierten Modellfehler (s. Gleichung 4.11).

Zunächst wird die Modellgüte, also die Qualität der Datenrepräsentation mit den vorliegenden Modellen, untersucht. Dazu wird der RMSE (root mean square error) des Vorhersagefehlers, als ein absolutes Fehlermaß, auf den artefaktfreien Datenabschnitten berechnet. Aus Gründen der Übersichtlichkeit wird für jeden Datensatz der Mittelwert des RMSE über alle Kanäle gebildet und anschließend für jede Parameterkombination über alle Datensätze gemittelt. Abbildung 4.8 zeigt die Ergebnisse. Die geringsten RMSE-Werte werden für AR-Modelle der Ordnung 15 und 20 erzielt. Das zeitvariable AR-Modell erreicht generell niedrigere RMSE-Werte als das stationäre Modell, was in der Adaptionfähigkeit auf Nicht-Stationaritäten der EEG-Zeitreihe begründet liegt. Insbesondere ist ein Prozessrauschen von $\sigma_w^2 = 10^{-5}$ optimal. Die RMSE-Werte für den Kalman-Filter mit zeitvariablen Messrauschen (s. Gleichung 4.28) sind nicht dargestellt, liegen aber ebenfalls im Bereich um 3,5.

Neben den Kanalmittelwerten wird auch die Modellgüte zwischen den Kanälen verglichen. Da der RMSE mit der Varianz des Kanals skaliert, ist er nicht geeignet, um verschiedene Kanäle zu vergleichen. Deshalb wird stattdessen der relative mean squared error (rMSE) verwendet (Schlögl, 2000):

$$rMSE = \frac{E[v^2]}{E[u^2]} = \frac{var(v)}{var(u)}.$$

Da $u(n)$ und $e(n)$ mittelwertfrei sind, entsprechen die Erwartungswerte der quadrierten Signale deren Varianz. Der rMSE kann als der durch den Fehlerterm erklärte Varianzanteil des Signals interpretiert werden. rMSE und rRMSE sind über die Beziehung $rMSE = rRMSE^2$ miteinander verknüpft. Abbildung 4.9 zeigt den rMSE für das zeitvariable AR-Modell ($M = 20, \sigma_w = 10^{-5}, \sigma_{vs} = 3\sigma_v$) und das stationäre AR-Modell ($M = 15$). Die beste Modellanpassung wird für parieto-zentrale Elektroden erzielt. Der Abfall nach okzipital und temporal deutet auf mehr Störungen in diesen Bereichen hin, was anatomisch plausibel erscheint, da dort die Einstreuungen von Nacken und Kiefermuskeln größer sind. Schwache Muskelkontraktionen können hier bereits einen Einfluss auf das EEG haben und sind mit dem bloßen Auge nicht immer erkennbar (Goncharova et al., 2003).

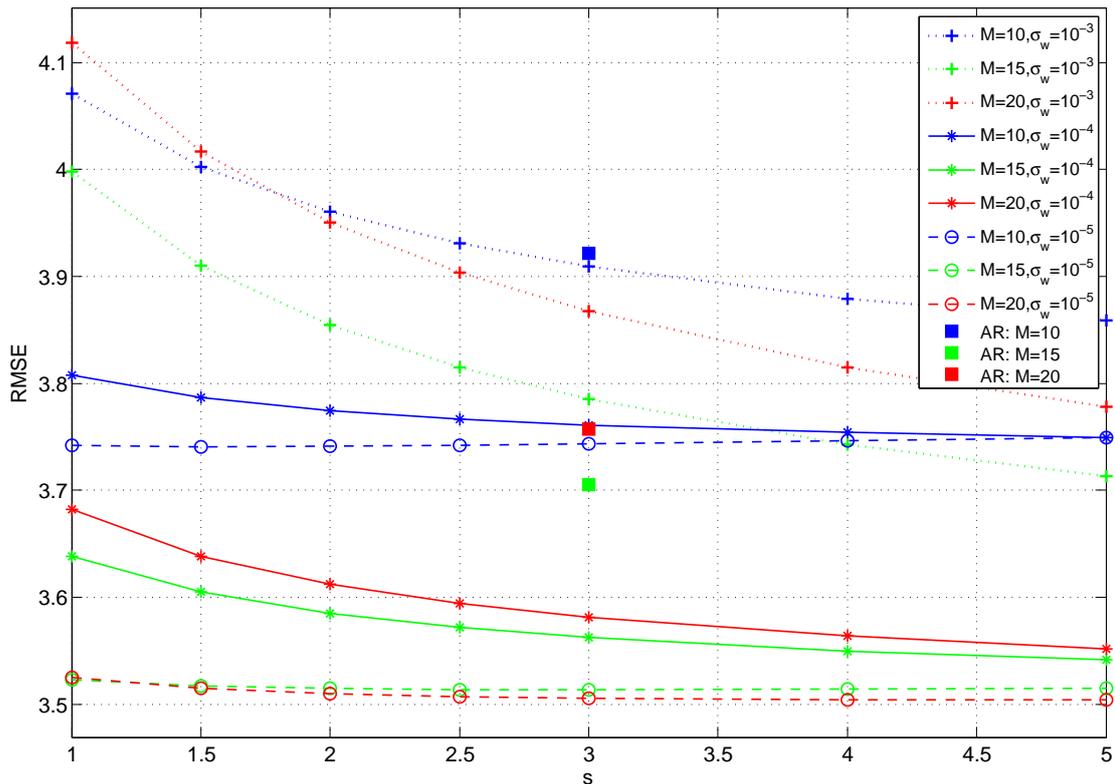


Abbildung 4.8: RMSE für verschiedene Modellparameter des stationären AR-Modells (farbige Quadrate) und des zeitvariablen AR-Modells mittels Kalman-Filter. Die x-Achse gibt den Skalierungsfaktor des Messrauschens an, welches aus der Baseline ermittelt wird: $\sigma_{vs}^2 = \sigma_v^2 s$. Für das stationäre AR-Modell ist dies kein freier Parameter. Die Platzierung der RMSE-Werte des stationären Modells (Quadrate) ist frei gewählt.

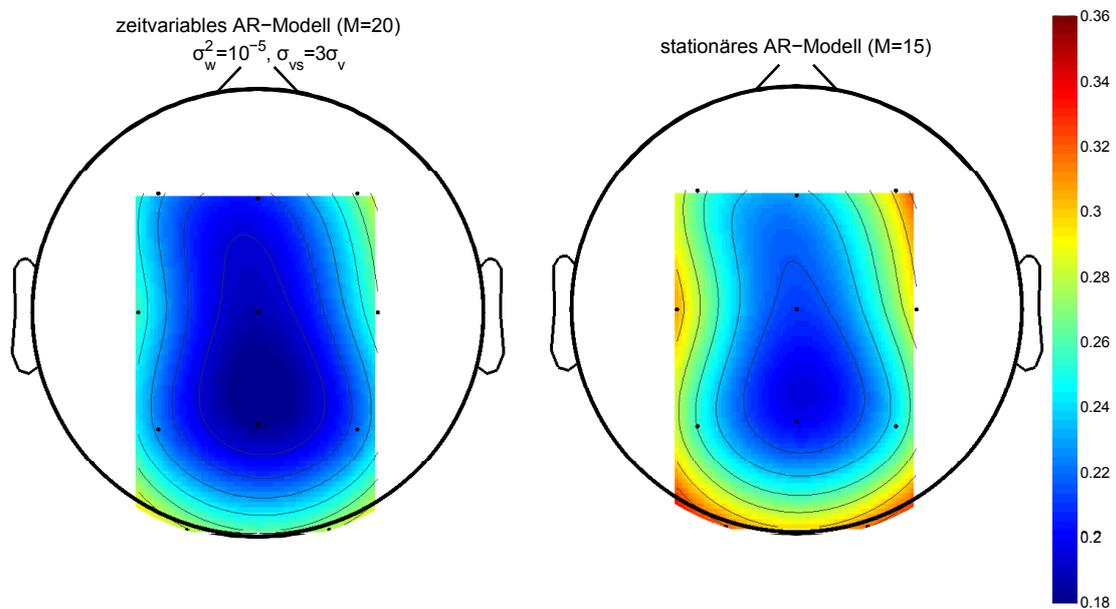


Abbildung 4.9: Topoplot des relativen MSE für das zeitvariable und stationäre AR-Modell mit jeweils optimaler Parameterkonfiguration (vgl. Abbildung 4.8). Der relative MSE gibt den Anteil der Varianz eines EEG-Kanals an, der durch den Fehlerterm erklärt wird. Niedrigere Werte deuten auf ein besseres Modell hin.

Im nächsten Schritt der Analyse werden die diskriminatorischen Fähigkeiten der Algorithmen bzgl. der Artefakte untersucht. Dazu wird eine kanalweise ROC-Analyse anhand der gelabelten Daten durchgeführt und verschiedene Parameterkonfigurationen getestet. Als Diskriminationsmerkmal dient der normierte Modellfehler 4.11, bzw. die normierte Innovation 4.27 mit einer gleitenden Summe von 0,4s Länge. Da für das stationäre AR-Modell die Fehlervarianz einen Einfluss auf die Normierung hat, werden auch hier skalierte Versionen der Baseline-Fehlervarianz getestet. Für das zeitvariable AR-Modell mit variablem σ_v^2 werden ebenfalls verschiedene Updatekoeffizienten μ (s. 4.28) untersucht. Abbildung 4.10 zeigt die Ergebnisse. Hier wird aus Gründen der Übersichtlichkeit der AUC-Wert über alle Kanäle und anschließend Datensätze gemittelt. Alle Algorithmen erzielen eine vergleichbar gute Performance. Die höchsten AUC-Werte erreicht das zeitvariable AR-Modell mit konstantem σ_v^2 . Insbesondere ist eine hohe Modellordnung von $M = 20$ und ein Prozessrauschen von $\sigma_w^2 = 10^{-4}$ optimal. Konträr dazu hat beim stationären AR-Modell eine niedrige Ordnung von $M = 5$ die beste Performance. Es ist anzunehmen, dass bei hohen Modellordnungen ein Overfitting auf die Baseline auftritt und abweichende Charakteristika der späteren Messung bereits erhöhte Modellfehler hervorrufen und damit die Diskrimination der Artefakte verschlechtern. Größere AUC-Werte können erreicht werden, wenn das Messrauschen σ_v^2 höher skaliert ist, als in der Baseline gemessen. Dies ist liegt darin begründet, dass sich der Hintergrundrauschpegel im Laufe der Messung im Vergleich zur Baseline erhöhen kann.

Um die kanalabhängige Performance zu untersuchen werden die AUC-Werte kanalweise über alle Datensätze gemittelt und in Topoplots aufgetragen. Abbildung 4.11 zeigt Topoplots für die beste Parameterkonfiguration. Bis auf okzipitale Kanäle ist die Performance vergleichbar zwischen den Kanälen. Die Kanäle O1 und O2 sind in mehreren Datensätzen stark verrauscht, was beim Labeln nicht immer beachtet wird, wodurch in artefaktfreien Segmenten häufig Störungen enthalten sind und zu den geringeren AUC-Werten führen.

Für die optimalen Parameter (stationäres Modell: $M = 5$, $\sigma_{v_s}^2 = 2,5\sigma_v^2$, zeitvariables AR-Modell: $M = 20$, $\sigma_{v_s}^2 = 2\sigma_v^2$, zeitvariables AR-Modell (σ_v^2 variabel): $M = 20$, $\mu = 1 - 10^{-4.5}$) zeigt Abbildung 4.12 die über Kanäle und Datensätze gemittelten ROC-Kurven sowie die zugehörigen Schwellwerte der Fehlerwahrscheinlichkeit $F_X = P(X \leq \bar{\epsilon}_\nu)$. Zur Mittelung werden die Klassifikationsrate (true positive rate, TPR) und der Schwellwert auf ein festes Fehlerratenraster (false positive rate, FPR) interpoliert und anschließend an diesen Punkten gemittelt. In

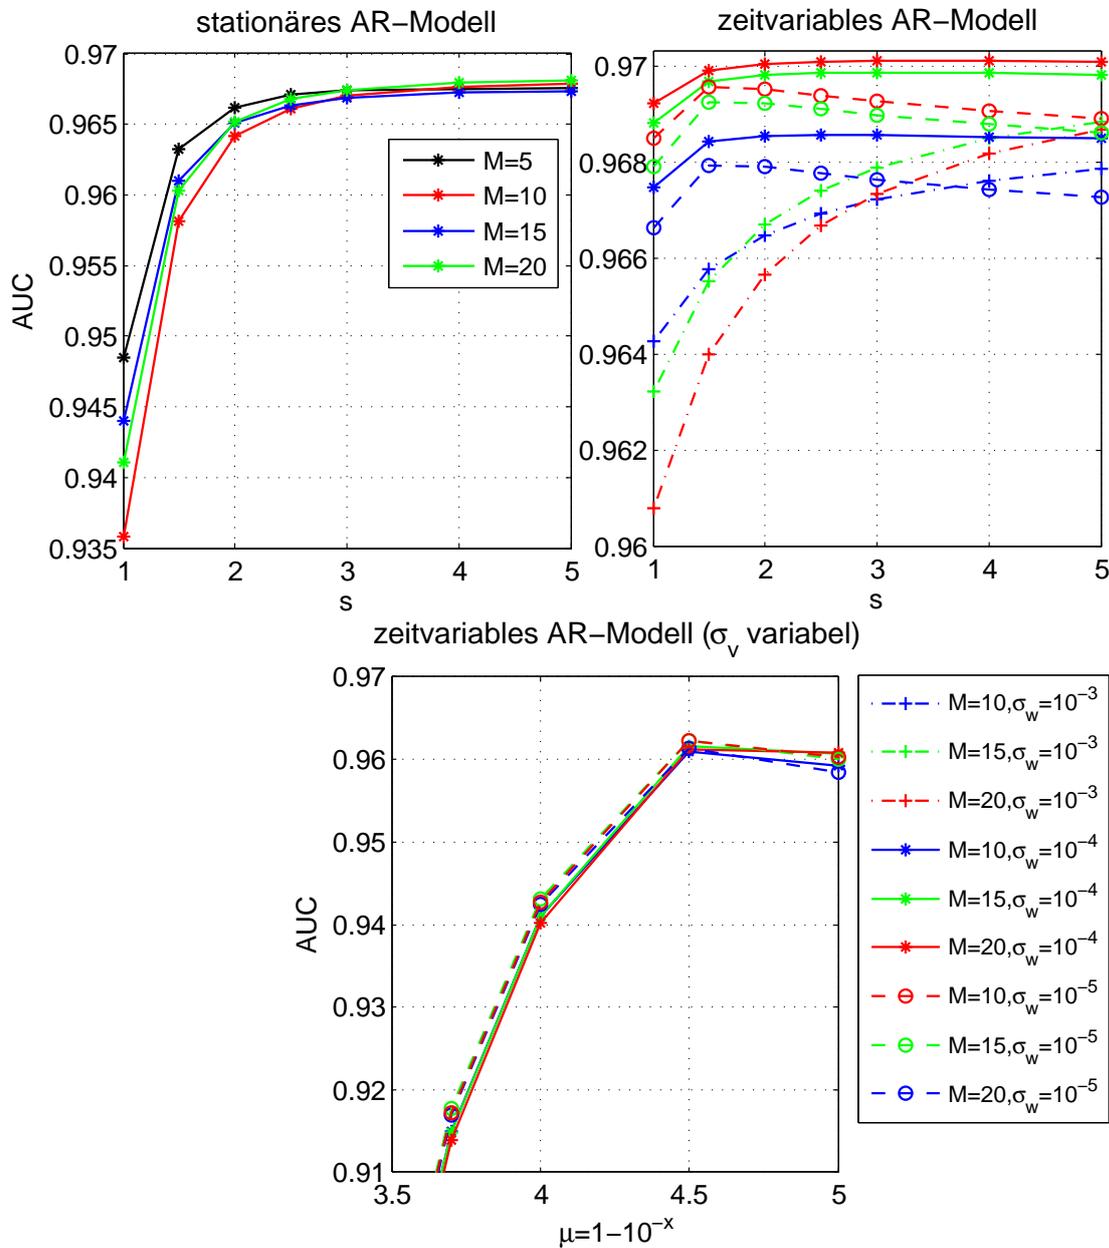


Abbildung 4.10: AUC-Werte für die Diskrimination zwischen artefaktfreien und artefaktbehafteten Daten. Die AUC-Werte werden über Kanäle und Datensätze gemittelt. Die x-Achse der oberen beiden Grafiken gibt den Skalierungsfaktor s der Baseline-Fehlervarianz an ($\sigma_{v_s}^2 = s\sigma_v^2$). Die unterschiedliche Skalierung der y-Achsen ist zu beachten. Für die rechte und untere Grafik gilt die untere Legende.

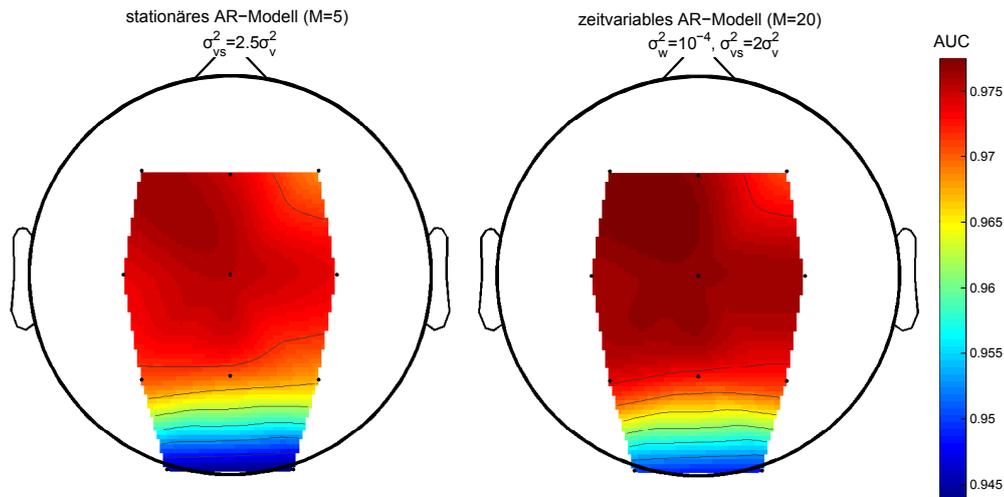


Abbildung 4.11: Topoplot der AUC-Werte gemittelt über alle 19 Datensätze für das stationäre AR-Modell (links) und das zeitvariable Modell mit festem σ_v^2 (rechts).

der Grafik ist zu sehen, dass bei einer Fehlerrate von z.B. 10% Klassifikationsraten von ca. 92% bzw. 90% erreicht werden. Zu bemerken sei allerdings, dass die recht niedrigen Schwellwerte von 0,1 bis 0,2 für gute Klassifikationsergebnisse in der Praxis zu niedrig sind. Grund hierfür ist das etwas ungenaue Labeln der Daten, wodurch auch immer wieder störungsfreie Daten als Artefakte markiert werden, was dazu führt, dass der optimale Schwellwert abgesenkt wird. In der Praxis sind Schwellwerte von 0,95 durchaus realistisch, was auch der üblichen Wahl für das Signifikanzniveau bei statistischen Tests entspricht.

Ein besonderes Augenmerk wird zusätzlich auf das Verhalten der Algorithmen beim Auftreten von Alpha-Spindeln gelegt. Da diese ebenfalls nicht-stationäre Ereignisse sind, besteht hier die Gefahr einer schlechten Modellanpassung und damit eine Klassifizierung der Spindeln als Artefakte. Zur Analyse werden nur Spindeln in artefaktfreien Abschnitten verwendet. Die mittlere Wahrscheinlichkeit $P(X \leq \bar{\epsilon}_\nu)$ der normierten Modellfehler bzw. Innovationen wird sowohl innerhalb der Spindeln als auch in den artefaktbehafteten Segmenten berechnet. Als Gütekriterium dient die Differenz der gemittelten Wahrscheinlichkeiten zwischen Spindeln und artefaktbehafteten Segmenten, welche auf $[0, 1]$ beschränkt ist. [Abbildung 4.13](#) zeigt die Ergebnisse. Ein hoher Differenzwert nahe 1 deutet auf eine gute Unterscheidbarkeit zwischen Artefakten und Spindeln hin. Alle drei Algorithmen sind vergleichbar in der Wahrscheinlichkeitsdifferenz. Die Modellordnung hat ebenfalls wenig Einfluss auf das Gütemaß. Es zeigte sich allerdings eine starke

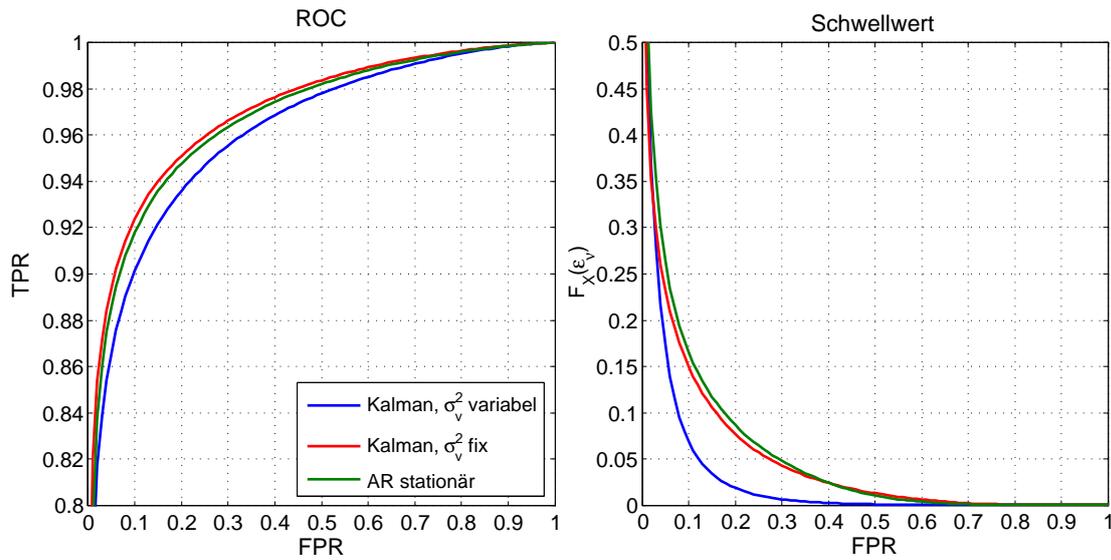


Abbildung 4.12: ROC Kurven (links) für die optimalen Parameter vertikal gemittelt über Kanäle und Datensätze sowie die zugehörigen Schwellwerte (rechts) der Fehlerwahrscheinlichkeit.

Abhängigkeit von der Skalierung der Baseline-Fehlervarianz bzw. des Updatekoeffizienten. Optimale Werte für das stationäre AR-Modell liegen bei $\sigma_{v_s}^2 = 2,5\sigma_v^2$, für das zeitvariable AR-Modell bei $\sigma_{v_s}^2 = 2\sigma_v^2$ und für das zeitvariable AR-Modell mit variablem σ_v^2 bei $\mu = 1 - 10^{-4,5}$.

Abschließend sind in Abbildung 4.14 beispielhaft die Parameter eines zeitvariablen AR(20)-Modells eines EEG-Datensegments mit Alpha-Spindeln und einem Artefakt (252,5–254,5s) dargestellt. In Zeile 2 der Grafik ist das zeitvariable Spektrum des AR-Modells zu sehen, welches mit Gleichung 4.7 zu jedem Zeitschritt bestimmt wird. Die Peaks im Alpha-Band während dem Auftreten von Alpha-Spindeln sind gut zu erkennen. Während dem Artefakt treten mehrere höherfrequente Komponenten auf. Zeile 3 zeigt die Fehlerwahrscheinlichkeit $F_X(\bar{\epsilon}_\nu)$ des Kalman-Filters und lässt erkennen, dass das AR-Modell während der Störung hohe Fehler aufweist und die Spektralschätzung damit unzuverlässig wird. Hier wird auch die weitreichendere Anwendbarkeit des zeitvariablen AR-Modells als parametrischer Spektralschätzer mit integrierter Modellgüteabschätzung ersichtlich. Zeile 4 zeigt die zugehörigen zeitvariablen AR-Koeffizienten.

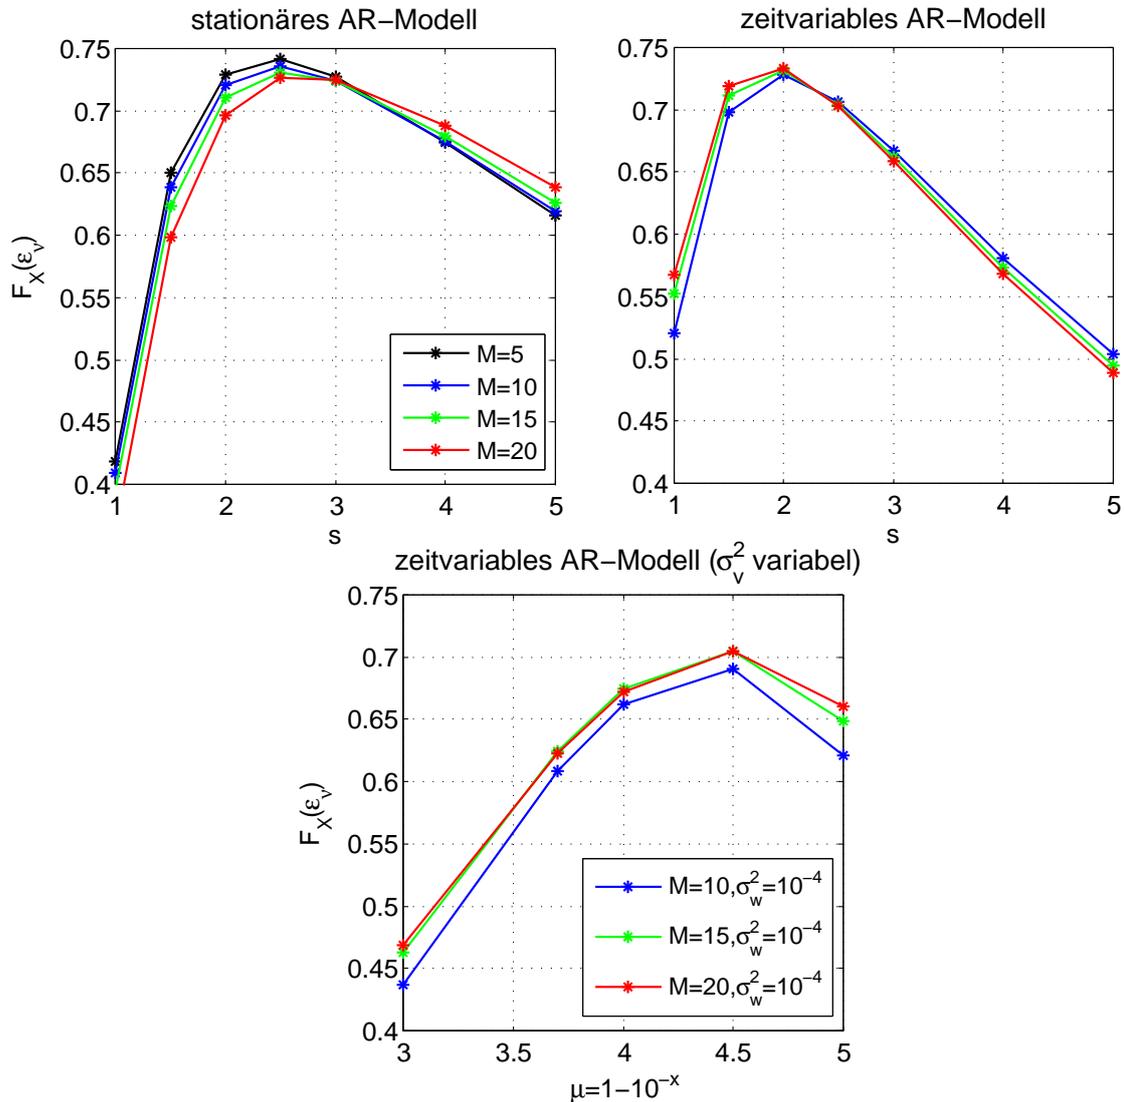


Abbildung 4.13: Differenz der mittleren Modellfehlerwahrscheinlichkeit zwischen Artefakten und Spindeln in artefaktfreien Abschnitten. Die Legende der unteren Grafik gilt auch für die obere rechte Grafik.

Zusammenfassung

Zusammenfassend kann gesagt werden, dass alle algorithmischen Varianten eine vergleichbare Performance liefern. Der sehr geringe Rechenaufwand für die Bestimmung des Vorhersagefehlers im stationären AR-Modell sowie dessen Einfachheit macht diese Variante besonders interessant für eine online-Anwendung. Allerdings ist die Verwendung des Kalman-Filters mit heutigen Computersystemen ebenfalls

problemlos möglich. Interessant bleibt die Alternative des Kalman-Filters mit zeitvariablen σ_v^2 . Trotz einer etwas schlechteren Performance kann diese Variante auch ohne Baseline-Messung angewendet werden. Bei der offline Verwendung des zeitvariablen AR-Modells kann die Genauigkeit der AR-Parameterschätzung, und damit der Artefaktdetektion, mit einem Kalman-Smoother (Bar-Shalom et al., 2001) deutlich verbessert werden.

Die Verwendung der Fehlerwahrscheinlichkeit 4.27 des jeweiligen Modells als Diskriminationsmerkmal für Artefakte ermöglicht, über ein simples Verwerfen von artefaktbehafteten Segmenten hinaus, eine Gewichtung der Daten anhand dieser Fehlerwahrscheinlichkeit. Beispielsweise kann jede Alpha-Spindel mit der inversen Fehlerwahrscheinlichkeit $1 - P(X \leq \bar{\epsilon}_v)$ multipliziert werden und anschließend die Spindelrate bestimmt werden. Dadurch geht keine Information aus den Daten verloren, stattdessen fließt eine Konfidenz über die Messqualität mit ein und findet so implizit bei nachfolgenden Analysen Berücksichtigung. Darüber hinaus entfällt die Wahl des optimalen Schwellwertes für die binäre Entscheidung ob ein Artefakt vorliegt oder nicht, welcher ohnehin zwischen verschiedenen Datensätzen schwanken kann und damit schwierig auf einen allgemeingültigen Wert festzulegen ist.

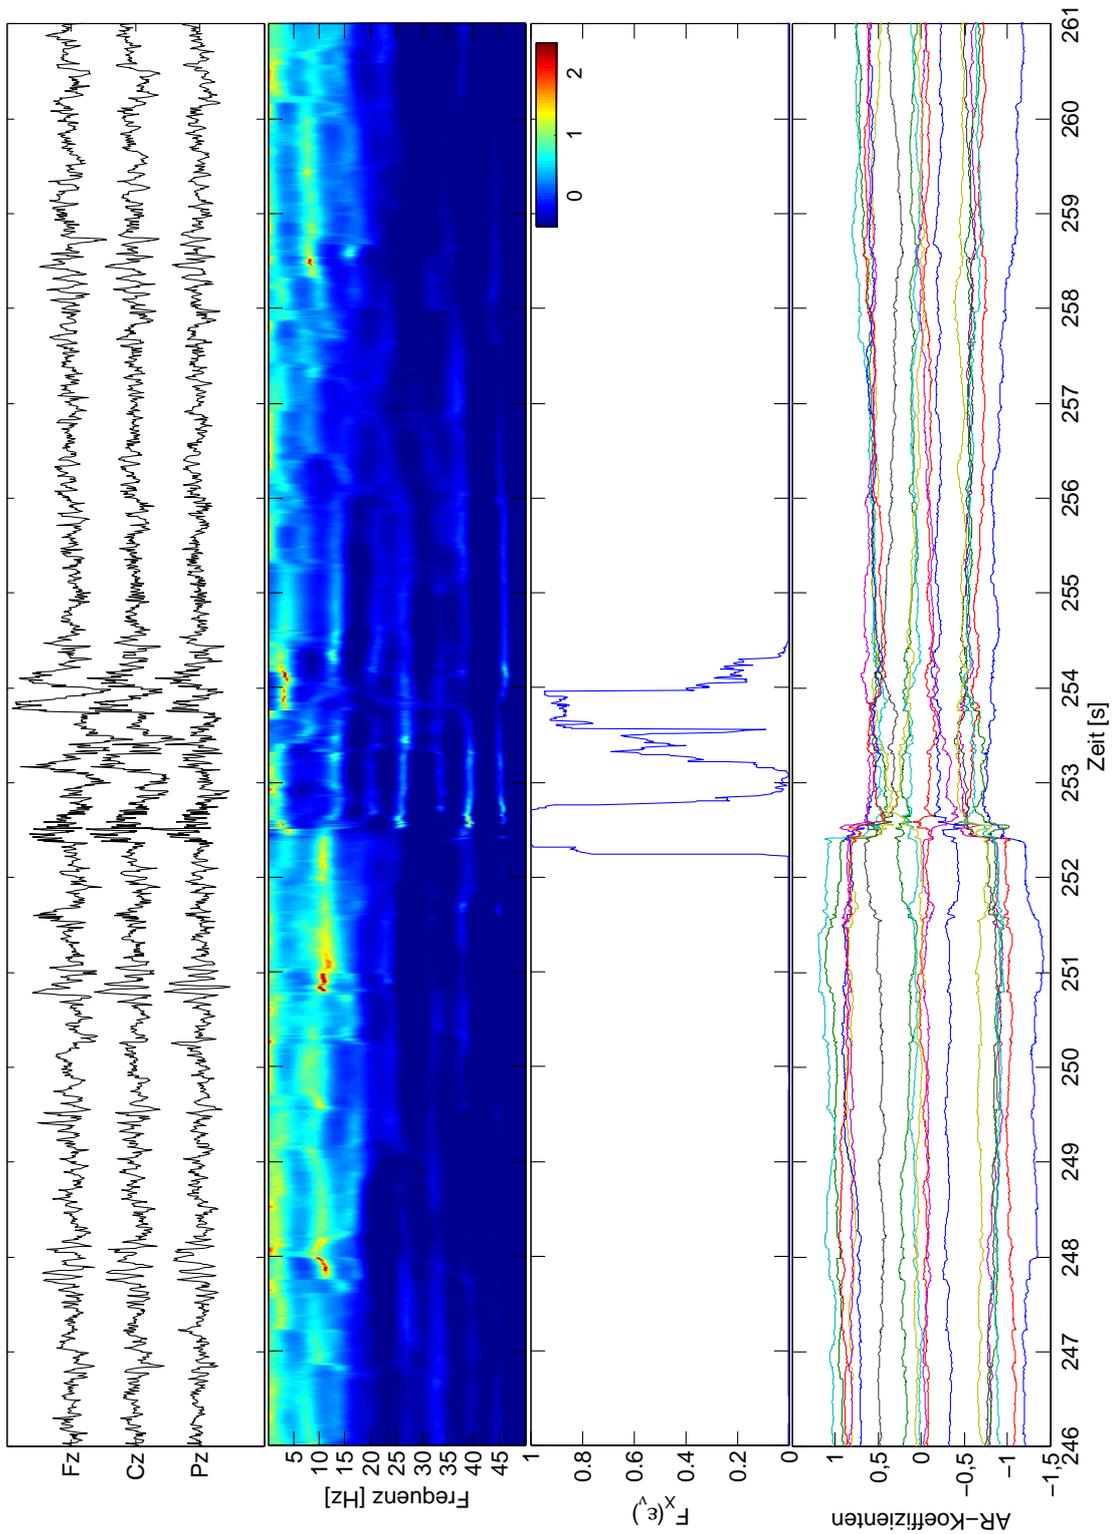


Abbildung 4.14: Beispiel des zeitvariablen AR-Modells mit festem σ_v^2 ($M = 20$, $\sigma_{vs}^2 = 2\sigma_v^2$, $\sigma_E^2 = 10^{-4}$). Zeile 1: EEG-Daten mit Alpha-Spindeln und einem Artefakt (252,5-254,5s). Zeile 2: AR-Spektrum für Kanal Pz. Zeile 3: Fehlerwahrscheinlichkeit. Zeile 4: zeitvariable AR-Koeffizienten.

Kapitel 5

Zusammenfassung und Ausblick

Müdigkeit und Unaufmerksamkeit spielen bei einer erheblichen Zahl von Verkehrsunfällen eine ursächliche Rolle. Besonders für Müdigkeit ist nicht nur bei Nachtfahrten ein erhöhtes Unfallrisiko zu erwarten, sondern auch am Nachmittag, einem zirkadianen Leistungstief, weshalb sich diese Arbeit auf monotone Tagfahrexperimente und die dabei entstehende Müdigkeit fokussiert.

Die Unfallzahlen belegen, dass die Selbsteinschätzung der Fahrer über ihre eigene Müdigkeit Mängel aufweist. Die vorliegende Arbeit zeigt ebenfalls Widersprüche zwischen der Selbsteinschätzung bei Tagfahrten, speziell gegen Ende der Fahrt, im Vergleich zu physiologischen Maßen (Alpha-Spindelrate, P300-Amplitude, Herzrate) und Leistungsmaßen (Reaktionszeit). Während diese objektiven Maße auf eine kontinuierliche Abnahme der Vigilanz hindeuten, schätzen sich die Fahrer in der letzten Stunde der Fahrt wacher ein, was durch verringerte Monotonie der Strecke und Motivationsveränderungen hervorgerufen wird und letztlich zu einer kritischen Überschätzung der eigenen Leistungsfähigkeit führen kann.

Aus diesem Grund ist die Entwicklung objektiver Indikatoren für Müdigkeit und Unaufmerksamkeit im Fahrkontext wichtig, um Fehleinschätzungen vorzubeugen und eine kontinuierliche Beobachtung des Vigilanzlevels zu ermöglichen. Diese Arbeit konzentriert sich auf die Analyse des EEGs zur Erkennung von Müdigkeit, da es sich in zahlreichen Vigilanzstudien als besonders sensitiv auf Veränderungen der Müdigkeit erwiesen hat. Da unklar ist inwieweit Erkenntnisse über Vigilanzveränderungen aus dem Labor sich auf Versuche im realen Straßenverkehr übertragen lassen, liegt der Schwerpunkt auf Experimenten unter realistischen Messbedingungen. Die Algorithmen zur Erkennung des Vigilanzniveaus werden speziell unter diesem Gesichtspunkt entwickelt und evaluiert, wobei ein Hauptaugenmerk auf

der Robustheit der Algorithmen gegenüber Störungen der Messung liegt.

Hauptuntersuchungsgegenstand im EEG ist das Alpha-Band als Indikator für Vigilanzprozesse. Hierfür wird eine Methode entwickelt, welche die besonderen morphologischen Eigenschaften des Alpha-Bandes detailliert charakterisiert. Dieses Verfahren erkennt automatisiert sog. Alpha-Spindeln und extrahiert relevante Eigenschaften wie Amplitude, Dauer, Frequenz und Auftretenshäufigkeit (Spindelrate). Damit ist es möglich die personenbezogenen Eigenschaften des Alpha-Bandes genau zu erfassen (Peakfrequenz innerhalb des Bandes) und eine erhöhte Robustheit gegenüber Artefakten zu erreichen. Für die Analyse von Müdigkeit ist vor allem die Mittelung dieser Merkmale in einem gleitenden Fenster von Vorteil.

Als Referenz für Müdigkeit werden Fahrten von Probanden verwendet, welche auf Grund starker Ermüdung die Fahrt frühzeitig abbrechen. Der Abbruch wird in diesem Zusammenhang als objektives Kriterium für sicherheitskritische Müdigkeit angesehen. Die statistischen Analysen zeigen, dass mehrere Spindelparameter verlässliche Indikatoren für starke Ermüdung sind, welche zum Abbruch der Fahrt führt. Klassische EEG-Maße wie Theta- und Alpha-Bandleistung zeigen zwar ähnliche Zusammenhänge, jedoch schwächer ausgeprägt und weniger spezifisch. Mit dem Verfahren zur Spindel detektion kann in diesem Zusammenhang eine zeitliche Auflösung von drei bis fünf Minuten erzielt werden, was für die Analyse von Müdigkeitsprozessen als ausreichend anzunehmen ist. Der Vergleich von Fahrt-Abbrechen und Nicht-Abbrechen macht deutlich, dass die Spindelmerkmale insbesondere sensitiv auf die Zunahme von sicherheitskritischer Müdigkeit, welche zum Abbruch führt, reagieren und damit eine Abgrenzung zu reinen time-on-task Effekten ermöglichen. Die Analysen zeigen jedoch auch, dass es erhebliche individuelle Unterschiede in der Ausprägung der Merkmale gibt.

Neben der Korrelation zwischen Alpha-Aktivität und Müdigkeit, steht die Alpha-Aktivität auch in Verbindung mit Aufmerksamkeitsprozessen. Hier kann erhöhte Aktivität über einem Kortexareal als aktive Inhibition und damit eine Hemmung der Informationsverarbeitung interpretiert werden, was besonders für visuelle Areale im parieto-okzipitalen Bereich zutrifft. Durch selektive Aufmerksamkeit kann die visuelle Verarbeitung gehemmt werden, um eine Konzentration auf andere Modalitäten oder internalisierte Aufmerksamkeit zu ermöglichen. In diesem Zusammenhang wird untersucht, ob die einzelne Alpha-Spindel ein Indikator für kurzzeitige Schwankungen selektiver Aufmerksamkeit ist. Dazu wird die Reaktionszeit und Detektionsrate auf akustische Stimuli, welche während einer Spindel auftreten mit solchen Stimuli verglichen, welche ohne Spindel auftreten. Verwen-

det werden lineare gemischte Modelle, um eine gruppenweise Mittelung über Stimuli zu vermeiden, wodurch die volle Variabilität der Daten berücksichtigt wird und somit ein realitätsnahes statistisches Modell zur Anwendung kommt. Die Ergebnisse zeigen, dass die Reaktionszeit auf akustische Stimuli, welche während einer Spindel auftreten, kürzer ist als die Reaktionszeit bei Stimuli, die nicht mit einer Alpha-Spindel zeitlich zusammenfallen. Die Detektionsgenauigkeit für die akustischen Stimuli ist höher, wenn der Stimulus während einer Spindel auftritt. Eine kurzzeitig bessere Performance in einer akustischen Aufgabe ist also gegeben, wenn gleichzeitig zur Aufgabe Alpha-Spindeln über dem parieto-okzipitalen Areal auftreten. Hierdurch wird ersichtlich, dass die Alpha-Spindel unter realen Messbedingungen ein Indikator für selektive Aufmerksamkeitsprozesse ist. Im Detail tritt durch aktive Inhibition des visuellen Kortex Spindelaktivität auf, was zu einer verbesserten akustischen Informationsverarbeitung führt. Liegt dagegen der Aufmerksamkeitsfokus auf visuellen Stimuli, verschwindet die Spindelaktivität und eine verschlechterte akustische Reaktionsfähigkeit ist die Folge. Die berechneten Effekte sind allerdings als schwach einzustufen, sodass der Einfluss einer einzelnen Alpha-Spindel auf Leistungsmaße, vor allem im Fahrkontext, praktisch nicht nachgewiesen werden kann. Die hohe Fehlervarianz des Modells zeigt, dass der Effekt einer Alpha-Spindel bei einer Einzelmessung durch die Variabilität anderer Störgrößen überlagert wird und somit nicht erkannt werden kann. Nur durch langfristige Beobachtungen und damit ein Eliminieren dieser Störgrößen, lassen sich diese Effekte replizieren, was deren direkte praktische Bedeutung im Fahrkontext herabsetzt.

Aufbauend auf der statistischen Evaluation der Spindelmerkmale hinsichtlich Müdigkeit, werden Ansätze untersucht, welche die automatisierte Klassifikation verschiedener Müdigkeitsstadien erlauben. Dabei ist gefordert, dass die Algorithmen echtzeitfähig sind und auf Grund des hohen zeitlichen Aufwandes keine probandenspezifische Kalibrierung benötigen. In einem ersten Schritt wird angestrebt einen Abschnitt zu Beginn der Fahrt (wach) von einem kurz vor Abbruch der Fahrt (ermüdet) mit Hilfe einer Diskriminanzanalyse zu separieren. Für diese Analyse kommen auch Merkmale des Lidschlagverhaltens zum Einsatz, da auch für diese ein Zusammenhang mit Müdigkeit aus der Literatur bekannt ist. Unter Verwendung einer quadratischen Diskriminanzanalyse können sehr gute Klassifikationsergebnisse erzielt werden, mit AUC-Werten von 0,96.

Ein weiterer Ansatz zur Klassifikation berücksichtigt auch Daten von Probanden, die den Versuch nicht abbrechen. Damit wird ein Selektionsbias durch Kon-

zentration auf die Abbrecher vermieden und die gesamte Fahrt beider Probandengruppen kann herangezogen werden. In dieser Analyse wird das Abbrucherereignis, bzw. ein fünf Minuten Abschnitt davor, versucht vorherzusagen. Mit Hilfe einer regularisierten logistischen Regression werden AUC-Werte von 0,845 erzielt, wobei die Fahrdauer, Spindelmerkmale und Merkmale des Lidschlagverhaltens relevant für die Prädiktion sind. Es zeigen sich deutliche Unterschiede in der Höhe der Abbruchwahrscheinlichkeit zwischen Abbrechern und Nicht-Abbrechern. Für praktische Systeme wäre eine höhere Klassifikationsperformance allerdings wünschenswert.

Die Aufnahme von EEG-Daten im Fahrzeug führt zu erheblichen Artefakten in den Aufzeichnungen. Einerseits rührt dies aus einer vermehrten Bewegung des Probanden und andererseits aus einer Reihe von technischen Störungen, welche in die Messung einstreuen. Um die Ergebnisse von statistischen Analysen und Klassifikationsalgorithmen nicht zu verfälschen, ist der adäquate Umgang mit Störungen entscheidend. Um mit den Verfahren zur Merkmalsextraktion und Klassifikation zu kooperieren, müssen Methoden zur Behandlung von Artefakten echtzeitfähig sein. Die Arbeit verfolgt dabei zwei Ansätze: Wo dies technisch möglich ist, wird die Bereinigung der EEG-Aufzeichnung von Artefakten verfolgt, andernfalls wird eine Erkennung artefaktbehafteter Abschnitte und der Ausschluss von der weiteren Verarbeitung angestrebt. Für EOG-Artefakte wird eine Bereinigung der EEG-Kanäle mittels multipler Regression durchgeführt. Dazu ist die Aufzeichnung einer kurzen Baseline zur Adaption der Regressionskoeffizienten notwendig. Über diese Methode wird eine deutliche Reduktion der EOG-Artefakte erreicht, jedoch ist keine vollständige Bereinigung möglich. Eine mögliche Erweiterung besteht in der Anwendung adaptiver Filter, sodass die Regressionskoeffizienten während des eigentlichen Experimentes ermittelt werden und somit keine Baseline mehr notwendig ist.

Für muskuläre und technische Artefakte wird der Ansatz verfolgt, gestörte Segmente zu detektieren und von der weiteren Analyse auszuschließen. Der daraus resultierende Verlust an Daten ist für die vorliegenden Experimente tolerierbar, da durch die mehrstündigen Aufzeichnungen nur ein geringer Prozentsatz verloren geht. Das vorgestellte Verfahren modelliert die EEG-Zeitreihe mittels autoregressiver Modelle und ermöglicht die Detektion von Artefakten auf Basis signifikant erhöhter Modellfehler kanalweise und samplegenau. Für die Anwendung des Verfahrens in Echtzeit ist wiederum eine Kalibrierung der Modellparameter anhand einer kurzen, artefaktfreien Baseline notwendig. Alternativ besteht die Möglichkeit

eines zeitvariablen AR-Modells, bei dem die Parameter über einen Kalman-Filter während der Laufzeit geschätzt werden. Eine Anwendung autoregressiver Modelle ohne Baseline ist somit auch möglich. Obwohl das EEG ein nicht-stationärer Prozess ist und damit adaptive Methoden besser zur Modellierung geeignet sind, zeigen beide Ansätze eine vergleichbare Detektionsperformance. Besondere Berücksichtigung wird auf die Fehlklassifikation von Spindeln als Artefakte gelegt, welche für beide Verfahren als gering angesehen werden kann. Der vorliegende Ansatz betrachtet jeden EEG-Kanal als unabhängig von seinen räumlichen Nachbarn. Eine Anwendung vektorautoregressiver Modelle (VAR) würde die Berücksichtigung dieser Abhängigkeiten ermöglichen. Damit ist die Erhöhung der Detektionsrate für Störungen an einzelnen Kanälen möglich.

Abschließend sei bemerkt, dass das Thema Müdigkeit im Straßenverkehr weiter an Relevanz zunimmt. Die fortschreitende Automation im Fahrzeug hat, neben allen positiven Aspekten, auch eine Zunahme der fahrerseitigen Monotonie und damit müdigkeitsinduzierender Umstände zur Folge. Weiterhin ist in der Gesellschaft eine kontinuierliche Abnahme der Schlafdauer zu beobachten, welche gepaart mit einer hohen Mobilität ein steigendes Risiko für müdigkeitsbedingte Unfälle in sich birgt. Systeme welche die Erkennung von Fahrerermüdung ermöglichen, können hier einen wichtigen, präventiven Beitrag leisten. Dabei bietet die vorgestellte Methodik der EEG Alpha-Spindeln eine objektive Referenz, welche wichtig ist, um Assistenzsysteme zur Beurteilung der Fahrervigilanz weiterzuentwickeln und zu bewerten. Das in dieser Arbeit vorgestellte System „Attention Assist“ von Mercedes-Benz, welches Müdigkeit anhand des Fahrvehaltens, im Speziellen sind dies Parameter des Lenkwinkels, quantifiziert, zeigt eine gute Übereinstimmung mit der Alpha-Spindelrate, insbesondere für starke Ermüdung, welche zum Fahrtabbruch führt. Für die Weiterentwicklung dieses Systems ist eine stärkere Berücksichtigung der Alpha-Spindelmethodik als objektive Referenz für Müdigkeit vorgesehen.

Anhang A

Veröffentlichungen

Im Rahmen dieser Dissertation wurden folgende Arbeiten veröffentlicht:

Konferenzbeiträge

Schubert, R., Tangermann, M., Haufe, S., Sannelli, C., **Simon, M.**, Schmidt, E.A., Kincses, W.E., Curio, G. (2008). Parieto-occipital alpha power indexes distraction during simulated car driving. *International Journal of Psychophysiology*, 69(3):214.

Schrauf, M., **Simon, M.**, Schmidt, E.A., Kincses, W.E. (2011). Assessing drivers' fatigue state under real traffic conditions using EEG alpha spindles. *6th International Driving Symposium on Human Factors in Driver Assessment*, in press.

Sonnleitner, A., **Simon, M.**, Kincses, W.E., Schrauf, M. (2011). Neurophysiological correlates of attentional shift during real road driving. *2nd International Conference on Driver Distraction and Inattention, Gothenburg, Sweden*.

Simon, M., Schrauf, M., Sonnleitner, A., Kincses, W.E. (2011). EEG Alpha Spindles as Indicators for Prolonged Brake Reaction Time During Auditory Secondary Tasks in a Real Road Driving Study. *Human Factors and Ergonomics Society Annual Meeting Proceedings*, 55, in press.

Zeitschriftenbeiträge

Schmidt, E.A., Schrauf, M., **Simon, M.**, Fritzsche, M., Buchner, A., Kincses, W.E. (2009). Driver's misjudgement of vigilance state during prolonged monotonous daytime driving. *Accident Analysis and Prevention*, 41:1087-1093.

Schmidt, E.A., Schrauf, M., **Simon, M.**, Buchner, A., Kincses, W.E. (2011). The short-term effect of verbally assessing drivers' state on vigilance indices during monotonous daytime driving. *Transportation Research Part F*, 14:251-260.

Simon, M., Schmidt, E.A., Fritzsche, M., Schrauf, M., Kincses, W.E., Aufmuth, C., Bruns, A., Bogdan, M., Rosenstiel, W. (2011). EEG Alpha Spindle Measures as Indicators of Driver Fatigue Under Real Traffic Conditions. *Clinical Neurophysiology*, 122:1168-1178.

Sonnleitner, A., **Simon, M.**, Kincses, W.E., Buchner, A., Schrauf, M (2012). Alpha Spindles as Neurophysiological Correlates Indicating Attentional Shift in a Simulated Driving Task. *International Journal of Psychophysiology*, in press

Literaturverzeichnis

- Baayen, R., Davidson, D., und Bates, D. (2008). Mixed-effects modeling with crossed random effects for subjects and items. *Journal of Memory and Language*, 59(4):390–412.
- Bahill, A. T., Brockenbrough, A., und Troost, B. T. (1981). Variability and development of a normative data base for saccadic eye movements. *Investigative Ophthalmology & Visual Science*, 21(1):116–25.
- Ballard, J. C. (1996). Computerized assessment of sustained attention: a review of factors affecting vigilance performance. *Journal of Clinical and Experimental Neuropsychology*, 18(6):843–863.
- Bar-Shalom, Y., Li, X.-R., und Kirubarajan, T. (2001). *Estimation with Applications to Tracking and Navigation*. John Wiley & Sons.
- Baranski, J. V. (2007). Fatigue, sleeploss, and confidence in judgment. *Journal of Experimental Psychology: Applied*, 13(4):182–196.
- Bates, D. M. und Sarkar, D. (2007). *lme4: Linear mixed-effects models using Eigen and classes, R package version 0.99875-6*.
- Baulk, S. D., Reyner, L. A., und Horne, J. A. (2001). Driver sleepiness - evaluation of reaction time measurement as a secondary task. *Sleep*, 24(6):695–698.
- Beck, N., Katz, J. N., und Tucker, R. (1998). Taking time seriously: Time-series-cross-section analysis with a binary dependent variable. *American Journal of Political Science*, 42(6):1260–1288.
- Belz, S. M., Robinson, G. S., und Casali, J. G. (2004). Temporal separation and self rating of alertness as indicators of driver fatigue in commercial motor vehicle operators. *Human Factors*, 46:154–169.

- Ben-Simon, E., Podlipsky, I., Arieli, A., Zhdanov, A., und Hendler, T. (2008). Never resting brain: Simultaneous representation of two Alpha related processes in humans. *PLoS ONE*, 3(12):e3984.
- Birbaumer, N. und Schmidt, R. F. (2006). *Biologische Psychologie*. Springer-Medizin Verlag, Heidelberg.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Information Science and Statistics. Springer.
- Bittner, R., Hána, K., Poušek, L., Smrka, P., Schreib, P., und Vysoký, P. (2000). Detecting of fatigue states of a car driver. In Brause, R. und Hanisch, E., editors, *Medical Data Analysis*, volume 1933 of *Lecture Notes in Computer Science*, pages 123–126. Springer Berlin / Heidelberg.
- Bortz, J. (2005). *Statistik für Human- und Sozialwissenschaftler*. Springer.
- Brockwell, P. J. und Davis, R. A. (2006). *Time Series: Theory and Methods*. Springer Series in Statistics. Springer, second edition.
- Brookhuis, K. A. und de Waard, D. (1993). The use of psychophysiology to assess driver status. *Ergonomics*, 36:1099–110.
- Brown, I. D. (1994). Driver fatigue. *Human Factors*, 36:298–314.
- Caffier, P. P., Erdmann, U., und Ullsperger, P. (2003). Experimental evaluation of eye-blink parameters as a drowsiness measure. *European Journal of Applied Physiology*, 89:319–325.
- Cajochen, C., Khalsa, S. B. S., Wyatt, J. K., Czeisler, C. A., und Dijk, D.-J. (1999). EEG and ocular correlates of circadian melatonin phase and human performance decrements during sleep loss. *Am J Physiol Regul Integr Comp Physiol*, 277(3):640–649.
- Campagne, A., Pebayle, T., und Muzet, A. (2004). Correlation between driving errors and vigilance level: influence of the driver's age. *Physiology and Behavior*, 80(4):515–524.
- Cantero, J. L., Atienza, M., Gómez, C., und Salas, R. M. (1999). Spectral structure and brain mapping of human Alpha activities in different arousal states. *Neuropsychobiology*, 39(2):110–116.

- Cantero, J. L., Atienza, M., Stickgold, R., Kahana, M. J., Madsen, J. R., und Kocsis, B. (2003). Sleep-dependent Theta oscillations in the human hippocampus and neocortex. *Journal of Neuroscience*, 23(34):10897–10903.
- Cerezuela, G. P., Tejero, P., Chóliz, M., Chisvert, M., und Monteagudo, M. J. (2004). Wertheim’s hypothesis on ‘highway hypnosis’: empirical evidence from a study on motorway and conventional road driving. *Accident Analysis and Prevention*, 36(6):1045–1054.
- Connor, J., Norton, R., Ameratunga, S., Robinson, E., Civil, I., Dunn, R., Bailey, J., und Jackson, R. (2002). Driver sleepiness and risk of serious injury to car occupants: population based case control study. *BMJ*, 324(7346):1125.
- Cooper, N. R., Croft, R. J., Dominey, S. J. J., Burgess, A. P., und Gruzelier, J. H. (2003). Paradox lost? Exploring the role of Alpha oscillations during externally vs. internally directed attention and the implications for idling and inhibition hypotheses. *International Journal of Psychophysiology*, 47(1):65–74.
- Crick, F. (1984). Function of the thalamic reticular complex: the searchlight hypothesis. *Proceedings of the National Academy of Sciences*, 81(14):4586–4590.
- Croft, R. und Barry, R. (2000). Removal of ocular artifact from the eeg: a review. *Neurophysiologie Clinique/Clinical Neurophysiology*, 30(1):5–19.
- Curcio, G., Casagrande, M., und Bertini, M. (2001). Sleepiness: evaluating and quantifying methods. *International Journal of Psychophysiology*, 41(3):251–263.
- da Silva, F. L. (1991). Neural mechanisms underlying brain waves: from neural membranes to networks. *Electroencephalography and Clinical Neurophysiology*, 79(2):81–93.
- Daimler AG (2008). HighTech Report 02. Technical report.
- Davidson, P. R., Jones, R. D., und Peiris, M. T. (2007). EEG-based lapse detection with high temporal resolution. *IEEE Transactions on Biomedical Engineering*, 54:832–839.
- Dawson, D., Fletcher, A., und Hussey, F. (2000). *Beyond the Midnight Oil: Managing Fatigue in Transport*. Standing Committee on Communications, Transport and the Arts, Canberra, Australia.

- Dawson, D. und Reid, K. (1997). Fatigue, alcohol and performance impairment. *Nature*, 388:235.
- DeLong, E. R., DeLong, D. M., und Clarke-Pearson, D. L. (1988). Comparing the areas under two or more correlated receiver operating characteristic curves: A nonparametric approach. *Biometrics*, 44:837–845.
- Delorme, A. und Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134:9–21.
- Delorme, A., Sejnowski, T., und Makeig, S. (2007). Enhanced detection of artifacts in EEG data using higher-order statistics and independent component analysis. *Neuroimage*, 34:1443–1449.
- Desmond, P. A. und Matthews, G. (2009). Individual differences in stress and fatigue in two field studies of driving. *Transportation Research Part F*, 12(4):265–276.
- DESTATIS (2009). *Unfallentwicklung auf deutschen Strassen 2008*. Statistisches Bundesamt, Wiesbaden.
- Dinges, D. F. (1995). An overview of sleepiness and accidents. *Journal of Sleep Research*, 4:4–14.
- Dinges, D. F., Mallis, M. M., Maislin, M. A., und Powell, J. W. (1998). *Evaluation of techniques for ocular measurement as an index of fatigue and the basis for alertness management*. US Dept of Transportation, Washington, DC. Report DOT HS 808762.
- Dinges, D. F. und Powell, J. W. (1985). Microcomputer analyses of performance on a portable simple visual RT task during sustained operations. *Behavior research methods, instruments and computers*, 17(6):652–655.
- Dixon, K., Hagemann, K., Basilico, J., Forsythe, C., Rothe, S., Schrauf, M., und Kincses, W. (2009). Improved team performance using EEG- and context-based cognitive-state classifications for a vehicle crew. In Schmorow, D., Estabrooke, I., und Grootjen, M., editors, *Foundations of Augmented Cognition. Neuroergonomics and Operational Neuroscience*, volume 5638 of *Lecture Notes in Computer Science*, pages 365–372. Springer.

- Drummond, S. P. A., Brown, G. G., Stricker, J. L., Buxton, R. B., Wong, E. C., und Gillin, J. C. (1999). Sleep deprivation-induced reduction in cortical functional response to serial subtraction. *Neuroreport*, 10:3745–3748.
- Duda, R. O., Hart, P. E., und Stork, D. (2000). *Pattern Classification*. John Wiley & Sons, second edition.
- Dureman, E. und Bodén, C. (1972). Fatigue in simulated car driving. *Ergonomics*, 15(3):299–308.
- E. J. Caille, J. L. B. (1977). Validation of a behavior analysis methodology: variation of vigilance in night driving as a function of the rate of carboxyhemoglobin. In Mackie, R., editor, *Vigilance*, pages 59–72. Plenum Press, New York.
- Engel, A. K., Fries, P., und Singer, W. (2001). Dynamic predictions: Oscillations and synchrony in top-down processing. *Nature Reviews Neuroscienc*, 2(10):704–716.
- Eoh, H. J., Chung, M. K., und Kim, S.-H. (2005). Electroencephalographic study of drowsiness in simulated driving with sleep deprivation. *International Journal of Industrial Ergonomics*, 35(4):307–320.
- Ergenoglu, T., Demiralp, T., Bayraktaroglu, Z., Ergen, M., Beydagi, H., und Uresin, Y. (2004). Alpha rhythm of the EEG modulates visual detection performance in humans. *Cognitive Brain Research*, 20(3):376–383.
- Fahrmeir, L., Kneib, T., und Lang, S. (2007). *Regression: Modelle, Methoden und Anwendungen*. Springer.
- Fairclough, S. H. und Graham, R. (1999). Impairment of driving performance caused by sleep deprivation or alcohol: A comparative study. *Human Factors and Ergonomics Society*, 41(1):118–128.
- Fatourechi, M., Bashashati, A., Ward, R. K., und Birch, G. E. (2007). EMG and EOG artifacts in brain computer interface systems: A survey. *Clinical Neurophysiology*, 118(3):480–494.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8):861–874.

- Ferree, T. C., Luu, P., Russell, G. S., und Tucker, D. M. (2001). Scalp electrode impedance, infection risk, and EEG data quality. *Clinical Neurophysiology*, 112(3):536–544.
- Fisher, R. A. (1954). *Statistical methods for research workers*. Hafner Publishing, twelfth edition.
- Fitzgibbon, S. P., Powers, D. M. W., Pope, K. J., und Clark, C. R. (2007). Removal of eeg noise and artifact using blind source separation. *Journal of Clinical Neurophysiology*, 24(3):232–243.
- Folkard, S. (1997). Black times: temporal determinants of transport safety. *Accident Analysis and Prevention*, 29(4):417–430.
- Foxe, J. J., Simpson, G. V., und Ahlfors, S. P. (1998). Parieto-occipital ~ 10 Hz activity reflects anticipatory state of visual attention mechanisms. *Neuroreport*, 9(17):3929–3933.
- Friedman, J., Hastie, T., und Tibshirani, R. (2010). Regularization paths for generalized linear models via coordinate descent. *Journal of Statistical Software*, 33(1):1–22.
- Friedrichs, F. und Yang, B. (2010a). Camera-based drowsiness reference for driver state classification under real driving conditions. In *IEEE Intelligent Vehicles Symposium (IV)*, pages 101–106, San Diego, CA.
- Friedrichs, F. und Yang, B. (2010b). Drowsiness monitoring by steering and lane data based features under real driving conditions. In *European Signal Processing Conference EUSIPCO*, volume 18, pages 209–213, Aalborg, Denmark.
- Fukunaga, K. (1990). *Introduction to Statistical Pattern Recognition*. Computer Science & Scientific Computing. Academic Press Inc., second edition.
- Galley, L., Hentschel, E. H., Kuhn, K. P., und Stolzmann, W. (2006a). Verfahren und Steuergerät zum fahrerindividuellen Erkennen von Unaufmerksamkeiten des Fahrers eines Fahrzeuges. Pr.: DE 10 2005 026 457.
- Galley, L., Hentschel, E. H., Kuhn, K. P., und Stolzmann, W. (2006b). Verfahren und Steuergerät zur Unaufmerksamkeitserkennung in Abhängigkeit von mindestens einem fahrerindividuellen Parameter. Pr.: DE 10 2005 026 479.

- Galley, L., Hentschel, E. H., Kuhn, K. P., und Stolzmann, W. (2006c). Verfahren und Vorrichtung zur Müdigkeitserkennung. Pr.: DE 10 2005 026 456.
- George, C. F., Nickerson, P. W., Hanly, P. J., Millar, T. W., und Kryger, M. H. (1987). Sleep apnoea patients have more automobile accidents. *Lancet*, 330(8556):447.
- Gersch, W. (1970). Spectral analysis of EEG's by autoregressive decomposition of time series. *Mathematical Biosciences*, 7(1-2):205–222.
- Gevins, A. S., Yeager, C. L., Zeitlin, G. M., Ancoli, S., und Dedon, M. F. (1977). On-line computer rejection of EEG artifact. *Electroencephalography and Clinical Neurophysiology*, 42(2):267–274.
- Goncharova, I. I., McFarland, D. J., Vaughan, T. M., und Wolpaw, J. R. (2003). EMG contamination of EEG: spectral and topographical characteristics. *Clinical Neurophysiology*, 114(9):1580–1593.
- Grandjean, E. (1979). Fatigue in industry. *British Journal of Industrial Medicine*, 35:175–186.
- Gratton, G., Coles, M. G. H., und Donchin, E. (1983). A new method for off-line removal of ocular artifact. *Electroencephalography and Clinical Neurophysiology*, 55(4):468–484.
- Graw, P., Kräuchi, K., Knoblauch, V., Wirz-Justice, A., und Cajochen, C. (2004). Circadian and wake-dependent modulation of fastest and slowest reaction times during the psychomotor vigilance task. *Physiology and Behavior*, 80:695–701.
- Halder, S., Bensch, M., Mellinger, J., Bogdan, M., Kübler, A., Birbaumer, N., und Rosenstiel, W. (2007). Online artifact removal for brain-computer interfaces using support vectormachines and blind source separation. *Computational Intelligence and Neuroscience*, Article ID: 82069.
- Hancock, P. A. und Verwey, W. B. (1997). Fatigue, workload and adaptive driver systems. *Accident Analysis and Prevention*, 29:495–506.
- Hanslmayr, S., Aslan, A., Staudigl, T., Klimesch, W., Herrmann, C. S., und Bäuml, K.-H. (2007). Prestimulus oscillations predict visual perception performance between and within subjects. *Neuroimage*, 37(4):1465–1473.

- Hartley, L., Horberry, T., Mabbot, N., und Krueger, G. (2000). *Review of fatigue detection and prediction technologies*. Murdoch University, Perth, Australia. National Road Transport Commission.
- Hastie, T., Tibshirani, R., und Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer Series in Statistics. Springer, second edition.
- Haykin, S. (1986). *Adaptive Filter Theory*. Information and System Sciences. Prentice-Hall, Englewood Cliffs, NJ.
- Hell, W. und Langwieder, K. (2001). *Einschlafunfälle im Straßenverkehr – Eine bisher oft verkannte Unfallursache*. Gesamtverband der Deutschen Versicherungswirtschaft.
- Häkkinen, H., Summala, H., Partinen, M., Tiihonen, M., und Silvo, J. (1999). Blink duration as an indicator of driver sleepiness in professional bus drivers. *Sleep*, 22(6):798–802.
- Hoddes, E., Zarcone, V., Smythe, H., Phillips, R., und Dement, W. C. (1973). Quantification of sleepiness: a new approach. *Psychophysiology*, 10:431–436.
- Hoetker, G. (2007). The use of logit and probit models in strategic management research: Critical issues. *Strategic Management Journal*, 28(4):331–343.
- Hoffmann, S. und Falkenstein, M. (2008). The correction of eye blink artefacts in the EEG: A comparison of two prominent methods. *PLoS ONE*, 3(8):e3004.
- Hole, G. J. (2007). *The psychology of driving*. Lawrence Erlbaum, Mahwah, NJ.
- Hori, T., Hayashi, M., und Morikawa, T. (1994). Topographic EEG changes and the hypnagogic experience. In Ogilvie, R. D. und Harsh, J. R., editors, *Sleep Onset: Normal and Abnormal Processes*. American Psychological Association, Washington.
- Horne, J. A. und Baulk, S. D. (2004). Awareness of sleepiness when driving. *Psychophysiology*, 41:161–165.
- Horne, J. A. und Reyner, L. (1999). Vehicle accidents related to sleep: a review. *Occupational and Environmental Medicine*, 56(5):289–294.

- Hosmer, D. W. und Lemeshow, S. (1998). *Applied Survival Analysis: Regression Modeling of Time to Event Data*. Wiley-Interscience, New York, NY.
- Hu, S. und Zheng, G. (2009). Driver drowsiness detection with eyelid related parameters by support vector machine. *Expert Systems with Applications*, 36(4):7651–7658.
- Hyvärinen, A., Karhunen, J., und Oja, E. (2001). *Independent Component Analysis*. John Wiley & Sons.
- Ingre, M., Åkerstedt, T., Peters, B., Anund, A., und Kecklund, G. (2006). Subjective sleepiness, simulated driving performance and blink duration: examining individual differences. *Journal of Sleep Research*, 15:47–53.
- Iwasaki, M., Kellinghaus, C., Alexopoulos, A. V., Burgess, R. C., Kumar, A. N., Han, Y. H., Lüders, H. O., und Leigh, R. J. (2005). Effects of eyelid closure, blinks, and eye movements on the electroencephalogram. *Clinical Neurophysiology*, 116(4):878–885.
- John, M., Risser, M., und Kobus, D. (2006). Toward a usable closed-loop attention management system: predicting vigilance from minimal contact head, eye, and EEG measures. In *Proceedings of the 2nd Annual Augmented Cognition*, San Francisco, CA.
- Johns, M. W. (1991). A new method for measuring daytime sleepiness: The Epworth Sleepiness Scale. *Sleep*, 14:540–545.
- Johns, M. W. (2000). A sleep physiologist’s view of the drowsy driver. *Transportation Research Part F: Traffic Psychology and Behaviour*, 3(4):241–249.
- Johnson, R. R., Popovic, D. P., Olmstead, R. E., Stikic, M., Levendowski, D. J., und Berka, C. (2011). Drowsiness/alertness algorithm development and validation using synchronized EEG and cognitive performance to individualize a generalized model. *Biological Psychology*, 87(2):241–250.
- Joyce, C. A., Gorodnitsky, I. F., und Kutas, M. (2004). Automatic removal of eye movement and blink artifacts from EEG data using blind component separation. *Psychophysiology*, 41(2):313–325.

- Jung, T.-P., Makeig, S., und Bell, A. J. (1996). Independent component analysis of electroencephalographic data. *Advances in Neural Information Processing Systems*, pages 145–151.
- Jung, T.-P., Makeig, S., Humphries, C., Lee, T.-W., McKeown, M. J., Iragui, V., und Sejnowski, T. J. (2000). Removing electroencephalographic artifacts by blind source separation. *Psychophysiology*, 37(2):163–178.
- Kandel, E. R., Schwartz, J. H., und Jessell, T. M. (2000). *Principles of Neural Science*. McGraw-Hill.
- Kecklund, G. und Åkerstedt, T. (1993). Sleepiness in long distance truck driving: an ambulatory EEG study of night driving. *Ergonomics*, 36(9):1007–1017.
- Kecklund, G. und Åkerstedt, T. (2004). *Report on methods and classification of stress, inattention and emotional states*. Stockholm, Sweden: Karolinska Institutet. IST Programme: Sensation (507231).
- Åkerstedt, T. und Gillberg, M. (1990). Subjective and objective sleepiness in the active individual. *International Journal of Neuroscience*, 52:29–37.
- King, L. M., Nguyen, H. T., und Lal, S. K. L. (2006). Early driver fatigue detection from electroencephalography signals using artificial neural networks. In *Engineering in Medicine and Biology Society EMBS. 28th Annual International Conference of the IEEE*, volume 28, pages 2187 – 2190, New York, NY.
- Klados, M. A., Papadelis, C., Lythari, C., und Bamidis, P. D. (2008). The removal of ocular artifacts from EEG signals: a comparison of performances for different methods. In *Proceedings of the 4th European Conference of the International Federation for Medical and Biological Engineering (ECIFMBE '08)*, volume 22 of *IFMBE Proceedings*, page 1259–1263, Antwerp, Belgium.
- Klimesch, W. (1996). Memory processes, brain oscillations and EEG synchronization. *International Journal of Psychophysiology*, 24:61–100.
- Klimesch, W. (1999). EEG Alpha and Theta oscillations reflect cognitive and memory performance: A review and analysis. *Brain Research Reviews*, 29:169–195.

- Klimesch, W., Doppelmayr, M., Russegger, H., Pachinger, T., und Schwaiger, J. (1998). Induced Alpha band power changes in the human EEG and attention. *Neuroscience Letters*, 244(2):73–76.
- Klimesch, W., Sauseng, P., und Hanslmayr, S. (2007). EEG Alpha oscillations: the inhibition-timing hypothesis. *Brain Research Reviews*, 53(1):63–88.
- Koelega, H. S., Verbaten, M. N., van Leeuwen, T. H., Kenemans, J. L., Kemner, C., und Sjouw, W. (1992). Time effects on event-related brain potentials and vigilance performance. *Biological Psychology*, 34(1):59 – 86.
- Lal, S. K. L. und Craig, A. (2001). A critical review of the psychophysiology of driver fatigue. *Biological Psychology*, 55:173–194.
- Lal, S. K. L. und Craig, A. (2002). Driver fatigue: Electroencephalography and psychological assessment. *Psychophysiology*, 39:313–321.
- Lal, S. K. L. und Craig, A. (2005). Reproducibility of the spectral components of the electroencephalogram during driver fatigue. *International Journal of Psychophysiology*, 55:137–143.
- Laurell, H. und Lisper, H. O. (1978). A validation of subsidiary reaction time against detection of roadside obstacles during prolonged driving. *Ergonomics*, 21:81–88.
- Lee, T.-W., Girolami, M., und Sejnowski, T. J. (1999). Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources. *Neural Computation*, 11:417–441.
- Löffler, G. und Maurer, A. (2011). Incorporating the dynamics of leverage into default prediction. *Journal of Banking & Finance*, 35(12):3351–3361.
- Liang, S. F., Lin, C. T., Wu, R. C., Chen, Y. C., Huang, T. Y., und Jung, T. P. (2005). Monitoring driver’s alertness based on the driving performance estimation and the EEG power spectrum analysis. *Conference Proceedings of the International Conference of IEEE Engineering in Medicine and Biology Society*, 6:5738–5741.
- Lin, C.-T., Wu, R.-C., Jung, T.-P., Liang, S.-F., und Huang, T.-Y. (2005). Estimating driving performance based on EEG spectrum analysis. *EURASIP Journal of Applied Signal Processing*, 19:3165–3174.

- Linkenkaer-Hansen, K., Nikulin, V. V., Palva, S., Ilmoniemi, R. J., und Palva, J. M. (2004). Prestimulus oscillations enhance psychophysical performance in humans. *The Journal of Neuroscience*, 24(45):10186–10190.
- Lisper, H. O., Laurell, H., und van Loon, J. (1986). Relation between time to falling asleep behind the wheel on a closed track and changes in subsidiary reaction time during prolonged driving on a motorway. *Ergonomics*, 29:445–453.
- Liu, C. C., Hosking, S. G., und Lenné, M. G. (2009). Predicting driver drowsiness using vehicle measures: Recent insights and future challenges. *Journal of Safety Research*, 40(4):239 – 245.
- Liu, J., Zhang, C., und Zheng, C. (2010). EEG-based estimation of mental fatigue by using KPCA-HMM and complexity parameters. *Biomedical Signal Processing and Control*, 5(2):124–130.
- Mackworth, N. H. (1957). Vigilance. *The Advancement of Science*, 53:389–393.
- Malmivuo, J. und Plonsey, R. (1995). *Bioelectromagnetism: Principles and Applications of Bioelectric and Biomagnetic Fields*. Oxford University Press, Oxford, New York.
- Mathewson, K. E., Gratton, G., Fabiani, M., Beck, D. M., und Ro, T. (2009). To see or not to see: Prestimulus Alpha phase predicts visual awareness. *The Journal of Neuroscience*, 29(9):2725–2732.
- Matsuo, F., Peters, J. F., und Reilly, E. L. (1975). Electrical phenomena associated with movements of the eyelid. *Electroencephalography and Clinical Neurophysiology*, 38(5):507–511.
- Mattes, S. (2003). The lane-change-task as a tool for driver distraction evaluation. In abd K. Kluth, H. S., Rausch, H., und Bubb, H., editors, *Quality of work and products in enterprises of the future*, pages 57–60. Ergonomia, Stuttgart.
- May, J. F. und Baldwin, C. L. (2009). Driver fatigue: The importance of identifying causal factors of fatigue when considering detection and countermeasures technologies. *Transportation Research Part F*, 12:218–224.

- Mazaheri, A., DiQuattro, N. E., Bengson, J., und Geng, J. J. (2011). Pre-stimulus activity predicts the winner of top-down vs. bottom-up attentional selection. *PLoS ONE*, 6(2):e16243.
- McMenamin, B. W., Shackman, A. J., Maxwell, J. S., Bachhuber, D. R., Koppenhaver, A. M., Greischar, L. L., und Davidson, R. J. (2010). Validation of ICA-based myogenic artifact correction for scalp and source-localized EEG. *NeuroImage*, 49:2416–2432.
- Meinold, P. E. (2005). *Psychologie des Lidschlags - eine literatur- und methodenkritische Studie*. Dissertation, Universität Köln.
- Miltner, W. H. R., Braun, C., Arnold, M., Witte, H., und Taub, E. (1999). Coherence of Gamma-band EEG activity as a basis for associative learning. *Nature*, 397(6718):434–436.
- Mognon, A., Jovicich, J., Bruzzone, L., und Buiatti, M. (2011). ADJUST: An automatic EEG artifact detector based on the joint use of spatial and temporal features. *Psychophysiology*, 48(2):229–240.
- Moller, H. J., Kayumov, L., Bulmash, E. L., Nhan, J., und Shapiro, C. M. (2006). Simulator performance, microsleep episodes, and subjective sleepiness: normative data using convergent methodologies to assess driver drowsiness. *Journal of Psychosomatic Research*, 61:335–342.
- Monk, T. H. (1989). A Visual Analogue Scale technique to measure global vigor and affect. *Psychiatry Research*, 27:89–99.
- Morris, T. L. und Miller, J. C. (1996). Electrooculographic and performance indices of fatigue during simulated flight. *Biological Psychology*, 42(3):343–360.
- NHTSA (2003). *Drowsy driving and automobile crashes*. National Highway Traffic Safety Administration. http://www.nhtsa.gov/people/injury/drowsy_driving1/drowsy.html.
- NHTSA (2006). *The 100-Car Naturalistic Driving Study, Phase II – Results of the 100-Car Field Experiment*. National Highway Traffic Safety Administration. Report DOT HS 810 593.
- Niedermeyer, E. und Silva, F. L. D. (2005). *Electroencephalography*. Lippincott Williams and Wilkins, Philadelphia, PA.

- O'Brien, R. G. und Kaiser, M. K. (1985). MANOVA method for analyzing repeated measures designs: An extensive primer. *Psychological Bulletin*, 97(2):316–333.
- Ogilvie, R. D. (2001). The process of falling asleep. *Sleep medicine reviews*, 5(3):247–270.
- O'Hanlon, J. F. und Kelley, G. R. (1977). Comparison of performance and physiological changes between drivers who perform well and poorly during prolonged vehicular operation. In Mackie, R., editor, *Vigilance*, pages 87–109. Plenum Press, New York.
- Oken, B. S., Salinsky, M. C., und Elsas, S. M. (2006). Vigilance, alertness, or sustained attention: physiological basis and measurement. *Clinical Neurophysiology*, 117:1885–1901.
- Olbrich, S., Mulert, C., Karch, S., Trenner, M., Leicht, G., Pogarell, O., und Hegerl, U. (2009). EEG-vigilance and BOLD effect during simultaneous EEG/fMRI measurement. *NeuroImage*, 45:319–332.
- Oppenheim, A. V. und Schaffer, R. W. (1989). *Discrete-Time Signal Processing*. Prentice-Hall, Englewood Cliffs, NJ.
- Otmani, S., Pebayle, T., Roge, J., und Muzet, A. (2005). Effect of driving duration and partial sleep deprivation on subsequent alertness and performance of car drivers. *Physiology and Behavior*, 84:715–724.
- Pack, A. I., Pack, A. M., Rodgman, E., Cucchiara, A., Dinges, D. F., und Schwab, C. W. (1995). Characteristics of crashes attributed to the driver having fallen asleep. *Accident Analysis and Prevention*, 27(6):769–775.
- Pal, N. R., Chuang, C.-Y., Ko, L.-W., Chao, C.-F., Jung, T.-P., Liang, S.-F., und Lin, C.-T. (2008). EEG-based subject- and session-independent drowsiness detection: an unsupervised approach. *EURASIP Journal of Advanced Signal Processing*, pages 1–11.
- Papadelis, C., Chen, Z., Kourtidou-Papadeli, C., Bamidis, P. D., Chouvarda, I., Bekiaris, E., und Maglaveras, N. (2007). Monitoring sleepiness with on-board electrophysiological recordings for preventing sleep-deprived traffic accidents. *Clinical Neurophysiology*, 118(9):1906–1922.

- Pereda, E., Gamundi, A., Rial, R., und Gonzalez (1998). Non-linear behaviour of human EEG - fractal exponent versus correlation dimension in awake and sleep stages. *Neuroscience Letters*, 250:91–94.
- Pfurtscheller, G. (2003). Induced oscillations in the Alpha band: Functional meaning. *Epilepsia*, 44(12):2–8.
- Pfurtscheller, G. und da Silva, F. H. L. (1999). Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical Neurophysiology*, 110(11):1842–1857.
- Pfurtscheller, G., Kalcher, J., Neuper, C., Flotzinger, D., und Pregenzer, M. (1996). On-line EEG classification during externally-paced hand movements using a neural network-based classifier. *Electroencephalography and Clinical Neurophysiology*, 99(5):416–425.
- Philip, P., Sagaspe, P., Moore, N., Taillard, J., Charles, A., Guilleminault, C., und Bioulac, B. (2005). Fatigue, sleep restriction and driving performance. *Accident Analysis and Prevention*, 37:473–478.
- Philip, P., Sagaspe, P., Taillard, J., Moore, N., Guilleminault, C., Sanchez-Ortuno, M., Åkerstedt, T., und Bioulac, B. (2003). Fatigue, sleep restriction and performance in automobile drivers: a controlled study in a natural environment. *Sleep*, 26(3):277–280.
- Picot, A., Charbonnier, S., und Caplier, A. (2008). On-line automatic detection of driver drowsiness using a single electroencephalographic channel. In *Engineering in Medicine and Biology Society, EMBS. Annual International Conference of the IEEE*, volume 30, pages 3864–3867, Vancouver, BC.
- Pinheiro, J. C. und Bates, D. M. (2000). *Mixed-Effects Models in S and S-Plus*. Springer.
- Posner, M. und Rafal, R. (1987). Cognitive theories of attention and the rehabilitation of attentional deficits. *Neuropsychological Rehabilitation*, pages 182–201.
- R Development Core Team (2011). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria.

- Ray, W. J. und Cole, H. W. (1985). EEG Alpha activity reflects attentional demands, and Beta activity reflects emotional and cognitive processes. *Science*, 228(4700):750–752.
- Rechtschaffen, A. und Kales, A. (1968). *A manual of standardized terminology, techniques and scoring system for sleep stages of human subjects*. Washington DC.
- Reyner, L. A. und Horne, J. A. (1998). Falling asleep whilst driving: are drivers aware of prior sleepiness? *International Journal of Legal Medicine*, 111:120–123.
- Rinne, H. und Specht, K. (2002). *Zeitreihen. Statistische Modellierung, Schätzung und Prognose*. Vahlen, München.
- Robin, X., Turck, N., Hainard, A., Tiberti, N., Lisacek, F., Sanchez, J.-C., und Muller, M. (2011). pROC: an open-source package for R and S+ to analyze and compare ROC curves. *BMC Bioinformatics*, 12(1).
- Roge, J., Pebayle, T., und Muzet, A. (2001). Variations of the level of vigilance and of behavioural activities during simulated automobile driving. *Accident Analysis and Prevention*, 33:181–186.
- Romei, V., Brodbeck, V., Michel, C., Amedi, A., Pascual-Leone, A., und Thut, G. (2008). Spontaneous fluctuations in posterior Alpha-band EEG activity reflect variability in excitability of human visual areas. *Cerebral Cortex*, 18(9):2010–2018.
- Romero, S., Mañanas, M. A., und Barbanoj, M. J. (2009). Ocular reduction in EEG signals based on adaptive filtering, regression and blind source separation. *Annals of Biomedical Engineering*, 37(1):176–191.
- Sadaghiani, S., Scheeringa, R., Lehongre, K., Morillon, B., Giraud, A.-L., und Kleinschmidt, A. (2010). Intrinsic connectivity networks, Alpha oscillations, and tonic alertness: A simultaneous electroencephalography/functional magnetic resonance imaging study. *Journal of Neuroscience*, 30(30):10243–10250.
- Santamaria, J. und Chiappa, K. H. (1987). The EEG of drowsiness in normal adults. *Journal of Clinical Neurophysiology*, 4(4).

- Schack, B., Bareshova, E., Grieszbach, G., und Witte, H. (1995). Methods of dynamic spectral analysis by self-exciting autoregressive moving average models and their application to analysing biosignals. *Medical and Biological Engineering and Computing*, 33:492–498.
- Schleicher, R., Briest, N. G. S., und Galley, L. (2008). Blinks and saccades as indicators of fatigue in sleepiness warnings: looking tired? *Ergonomics*, 51:982–1010.
- Schlögl, A. (2000). *The electroencephalogram and the adaptive autoregressive Model: Theory and Applications*. Dissertation, Technische Universität Graz.
- Schlögl, A., Keinrath, C., Zimmermann, D., Scherer, R., Leeb, R., und Pfurtscheller, G. (2007). A fully automated correction method of EOG artifacts in EEG recordings. *Clinical Neurophysiology*, 118(1):98–104.
- Schlögl, A., Ziehe, A., und Müller, K.-R. (2009). Automated ocular artifact removal: comparing regression and component-based methods. *Nature Precedings*, (713).
- Schmidt, E. A. (2010). *Die objektive Erfassung von Müdigkeit während monotoner Tagfahrten und deren verbale Selbsteinschätzung durch den Fahrer*. Dissertation, Heinrich-Heine-Universität Düsseldorf.
- Schmidt, E. A., Schrauf, M., Simon, M., Buchner, A., und Kincses, W. E. (2011). The short-term effect of verbally assessing drivers' state on vigilance indices during monotonous daytime driving. *Transportation Research Part F: Traffic Psychology and Behaviour*, 14(3):251–260.
- Schmidt, E. A., Schrauf, M., Simon, M., Fritzsche, M., Buchner, A., und Kincses, W. E. (2009). Drivers' misjudgement of vigilance state during prolonged monotonous daytime driving. *Accident Analysis and Prevention*, 41:1087–1093.
- Schreckenberger, M., Lange-Asschenfeld, C., Lochmann, M., Mann, K., Siessmeier, T., Buchholz, H.-G., Bartenstein, P., und Gründer, G. (2004). The thalamus as the generator and modulator of EEG Alpha rhythm: a combined PET/EEG study with lorazepam challenge in humans. *NeuroImage*, 22:637–644.
- Shaw, J. C. (2003). *The Brain's Alpha Rhythms and the Mind*. Elsevier, New York.

- Shen, K.-Q., Li, X.-P., Ong, C.-J., Shao, S.-Y., und Wilder-Smith, E. (2008). EEG-based mental fatigue measurement using multi-class support vector machines with confidence estimate. *Clinical Neurophysiology*, 119(7):1524–1533.
- Sieloff, S. (2009). *Die EEG-Alpha-Spindel als Indikator für Vigilanzfluktuationen im Fahrkontext*. Diplomarbeit, Heinrich-Heine-Universität Düsseldorf.
- Smiley, A. (2007). Fatigue and driving. In Dewar, R. und Olsen, P., editors, *Human Factors in Traffic Safety*, pages 103–122. Lawyers and Judges Publishing Co., Inc., Tucson, AZ.
- Sommer, D., Golz, M., Trutschel, U., und Edwards, D. (2009). Assessing driver's hypovigilance from biosignals. In Sloten, J., Verdonck, P., Nyssen, M., Haueisen, J., und Magjarevic, R., editors, *4th European Conference of the International Federation for Medical and Biological Engineering*, volume 22 of *IFMBE Proceedings*, pages 152–155. Springer Berlin Heidelberg.
- Sonnleitner, A., Simon, M., Kincses, W. E., Buchner, A., und Schrauf, M. (2012). Alpha spindles as neurophysiological correlates indicating attentional shift in a simulated driving task. *International Journal of Psychophysiology*, in press.
- Steriade, M. (1997). Synchronized activities of coupled oscillators in the cerebral cortex and thalamus at different levels of vigilance. *Cerebral Cortex*, 7:583–604.
- Sterman, M. (1996). Physiological origins and functional correlates of EEG rhythmic activities: Implications for self-regulation. *Applied Psychophysiology and Biofeedback*, 21:3–33.
- Stern, J. A., Boyer, D., und Schroeder, D. (1994). Blink rate: A possible measure of fatigue. *Human Factors*, 36:285–297(13).
- Strijkstra, A. M., Beersma, D. G., Drayer, B., Halbesma, N., und Daan, S. (2003). Subjective sleepiness correlates negatively with global Alpha (8-12 Hz) and positively with central frontal Theta (4-8 Hz) frequencies in the human resting awake electroencephalogram. *Neuroscience Letters*, 340(1):17–20.
- Subasi, A., Kiyimik, M. K., Akin, M., und Erogul, O. (2005). Automatic recognition of vigilance state by using a wavelet-based artificial neural network. *Neural Computing & Applications*, 14:45–55.

- Tallon-Baudry, C., Bertrand, O., Delpuech, C., und Pernie, J. (1997). Oscillatory Gamma-band (30-70 Hz) activity induced by a visual search task in humans. *Journal of Neuroscience*, 17(2):722–734.
- Tarajan, E. (2009). *Entwurf neuer Klassifikationsverfahren zur Müdigkeitsdetektion bei Autofahrern anhand von physiologischen Signalen*. Bachelorarbeit, Technische Universität Ilmenau.
- Tejero, P. und Choliz, M. (2002). Driving on the motorway: the effect of alternating speed on drivers activation level and mental effort. *Ergonomics*, 45:605–618.
- Thiffault, P. und Bergeron, J. (2003). Monotony of road environment and driver fatigue: a simulator study. *Accident Analysis and Prevention*, 35:381–391.
- Thomas, M., Sing, H., Belenky, G., Holcomb, H., Mayberg, H., Dannals, R., Wagner, H., Thorne, D., Popp, K., Rowland, L., Welsh, A., Balwinski, S., und Redmond, D. (2000). Neural basis of alertness and cognitive performance impairments during sleepiness. i. effects of 24 h of sleep deprivation on waking human regional brain activity. *Journal of Sleep Research*, 9:335–352.
- Thut, G., Nietzel, A., Brandt, S. A., und Pascual-Leone, A. (2006). Alpha-band electroencephalographic activity over occipital cortex indexes visuospatial attention bias and predicts visual target detection. *The Journal of Neuroscience*, 26(37):9494–9502.
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society*, 58(1):267–288.
- Tietze, H. und Hargutt, V. (2001). Zweidimensionale Analyse zur Beurteilung des Verlaufs von Ermüdung. *43. Tagung experimentell arbeitender Psychologen, Regensburg*. http://www.psychologie.uni-wuerzburg.de/methoden/texte/2001_tietze_hargutt_Zweidimensionale_Analyse.pdf.
- Ting, P.-H., Hwang, J.-R., Doong, J.-L., und Jeng, M.-C. (2008). Driver fatigue and highway driving: A simulator study. *Physiology and Behavior*, 94(3):448 – 453.

- Torsvall, L. und Åkerstedt, T. (1987). Sleepiness on the job: continuously measured EEG changes in train drivers. *Electroencephalography and Clinical Neurophysiology*, 66(6):502–511.
- Tran, Y., Wijesuriya, N., Tarvainen, M., Karjalainen, P., und Craig, A. (2009). The relationship between spectral changes in heart rate variability and fatigue. *Journal of Psychophysiology*, 23(3):143–151.
- Trejo, L. J., Kochavi, R., Kubitz, K., Montgomery, L. D., Rosipal, R., und Matthews, B. (2005). EEG-based estimation of cognitive fatigue. In *Bio-monitoring for physiological and cognitive performance during military operations*, volume 5797 of *Proceedings of SPIE*, Orlando, FL.
- U.S. Department of Transportation, F. H. A. (1999). *Eye-activity measures of fatigue and napping as a fatigue countermeasure*. Federal Highway Administration, Washington DC. Final Report, FHWA-MC-99-028.
- van de Velde, M., Ghosh, I. R., und Cluitmans, P. J. M. (1999). Context related artefact detection in prolonged EEG recordings. *Computer Methods and Programs in Biomedicine*, 60(3):183–196.
- van de Velde, M., van Erp, G., und Cluitmans, P. J. M. (1998). Detection of muscle artefact in the normal human awake EEG. *Electroencephalography and Clinical Neurophysiology*, 107(2):149–158.
- van Dijk, H., Schoffelen, J.-M., Oostenveld, R., und Jensen, O. (2008). Prestimulus Oscillatory Activity in the Alpha Band Predicts Visual Discrimination Ability. *Journal of Neuroscience*, 28(8):1816–1823.
- Verbeke, G. und Molenberghs, G. (2001). *Linear mixed models for longitudinal data*. Springer.
- Vigário, R. N. (1997). Extraction of ocular artefacts from eeg using independent component analysis. *Electroencephalography and Clinical Neurophysiology*, 103(3):395–404.
- Vuckovic, A., Popovic, D., und Radivojevic, V. (2002). Artificial neural network for detecting drowsiness from EEG recordings. In *Neural Network Applications in Electrical Engineering, NEUREL*, volume 6, pages 155–158, Belgrad, Serbien.

- Wagenmakers, E. J., Farrell, S., und Ratcliff, R. (2004). Estimation and interpretation of $1/f^\alpha$ noise in human cognition. *Psychonomic Bulletin and Review*, 11(4):579–615.
- Wertheim, A. H. (1991). Highway hypnosis: A theoretical analysis. In Gale, A. G., Brown, I., Haslegrave, C. M., Moorhead, I., und Taylor, S. P., editors, *Vision in Vehicles III*. Elsevier.
- Wickens, V. D. (1984). Processing resources in attention. In Parasuraman, R. und Davies, D. R., editors, *Varieties of attention*. Academic Press, Orlando.
- Wilhelm, B., Giedke, H., Lüdtke, H., Bittner, E., Hofmann, A., und Wilhelm, H. (2001). Daytime variations in central nervous system activation measured by a pupillographic sleepiness test. *Journal of Sleep Research*, 10:1–7.
- Williamson, A. M. und Feyer, A.-M. (2000). Moderate sleep deprivation produces impairments in cognitive and motor performance equivalent to legally prescribed levels of alcohol intoxication. *Occupational and Environmental Medicine*, 57(10):649–655.
- Wright, N. und McGown, A. (2001). Vigilance on the civil flight deck: incidence of sleepiness and sleep during long-haul flights and associated changes in physiological parameters. *Ergonomics*, 44(1):82–106.
- Xie, L.-L. und Ljung, L. (2004). Variance expressions for spectra estimated using auto-regressions. *Journal of Econometrics*, 118:247–256.
- Yeo, M. V. M., Li, X., Shen, K., und Wilder-Smith, E. P. V. (2009). Can SVM be used for automatic EEG detection of drowsiness during car driving? *Safety Science*, 47(1):115–124.
- Zschocke, S. (2002). *Klinische Elektroenzephalographie*. Springer, 2. überarb. u. erw. Aufl. edition.