

Analyse des Mikroschlafs mit Methoden der Computergestützten Intelligenz

DISSERTATION

Zur Erlangung des akademischen Grades

Doktor-Ingenieur (Dr.-Ing.)

vorgelegt der
Fakultät für Informatik und Automatisierung
der Technischen Universität Ilmenau

von
Diplom-Informatiker (FH) David Sommer

Kurzfassung

Die überwiegende Zahl der Verkehrsunfälle ist durch Humanfaktoren bedingt. Hierbei sind extreme Hypovigilanz, plötzliche Aufmerksamkeitsverluste und Mikroschlafepisoden (MSE) besonders gefährlich. Zu ihrer Vermeidung nehmen unter den technischen Gegenmaßnahmen vor allem die automatische Erkennung und die Prognose solcher Spontanzustände eine zentrale Stellung ein. Auf dem Markt aktuell vorliegende Geräte basieren überwiegend auf der kontaktlosen Messung von okulomotorischen Variablen, insbesondere Lidschlagvariablen. Zur Validierung dieser Geräte wird eine Labor-Referenzmethode benötigt. Ziel dieser Arbeit ist deren Entwicklung, Optimierung und Validierung.

Die Auswertung der wissenschaftlichen Literatur der letzten Jahrzehnte zeigt, dass die Themenstellung komplex ist und dass eine umfassende Theorie zu den psychophysiologischen Bedingungen und zu den Abläufen noch im Entstehen ist. Es wird begründet, warum sich elektrophysiologische Signale, wie das Elektroenzephalogramm (EEG) und das Elektrookulogramm (EOG), als aussichtsreiche Zugänge für die Detektion von MSE erweisen.

Die Befundung, das heißt die Begutachtung des Probandenverhaltens, insbesondere vor und während Mikroschlafereignissen, wird in dieser Arbeit durch visuelle Beobachtungen von mehreren Experten ausgeführt. Dabei gehören Video-Nahaufnahmen des Auges und Videoaufnahmen der Fahrtszene zu den wichtigsten Informationsquellen. Es wurden nur evidente Ereignisse und evidente Gegenbeispiele befundet; Episoden mit unsicherer Befundung wurden verworfen.

Die Extraktion von Merkmalen aus EEG und EOG wurde im Wesentlichen durch Methoden zur Schätzung der spektralen Leistungsdichten und einer kürzlich eingeführten Methode im Zustandsraum, der Delay-Vektor-Varianz, realisiert. Erstere Methodik nimmt an, dass die Signale linear sind, während letztere auch nichtlineare Signalanteile und Stochastizität parametrisiert. Es wird gezeigt, dass für die Minimierung der empirischen Klassifikationsfehler die zeitliche Region der Signalanalyse exakt zu optimieren ist und neben der Fusion vieler Merkmale aus allen Signalen auch eine Reduktion korrelierender Merkmale auszuführen ist.

Für die automatische Klassifikation wurden sowohl einfache, lokale und einfache, globale Methoden als auch lernfähige Methoden verwendet, die mit und ohne Regularisierung der Diskriminanzfunktion arbeiten. Zudem wurden Klassifikatoren mit automatisch adaptierender Metrik eingesetzt, die sich zur Wissensextraktion eignen. Stark gewichtete Merkmale besitzen hohe Relevanz, denn sie dominieren die Distanzberechnungen. Am erfolgreichsten erwies sich in der vorliegenden Anwendungsdomäne die Support-Vektor-Maschine (SVM), deren Hyperparameter für verschiedene Kernfunktionen empirisch optimiert werden mussten. Für eine Probandengruppe (N=22) konnten mittlere Testfehler von 9,8 % erreicht werden.

Die nahezu verzerrungsfreie Leave-One-Out-Validierung konnte effizient für die rechenaufwendige SVM verwendet werden. Hold-Out-Strategien wurden auch auf Datensätze kompletter Versuchsnächte und einzelner Probanden angewendet. Mit ersterer wurde die zeitliche Stabilität und mit letzterer die Personenunabhängigkeit validiert. Es zeigte sich, dass sich die klassenbedingten Verteilungsdichten inter-individuell stark unterscheiden.

Für einzelne Probanden wurde an evidenten Datenbeispielen eine SVM adaptiert und optimiert und anschließend an fortlaufenden Datensegmenten abgerufen. Diese fortlaufende Klassifikation konnte positiv validiert und damit die Hypothese bestätigt werden, dass eine Sensorapplikation basierend auf elektrophysiologischen Signalen möglich ist. Die Ergebnisse wurden mit denen einer anderen Forschungsgruppe verglichen.

Zusammenfassend lässt sich feststellen, dass die vorgeschlagene Lösung das Potential für einen Labor-Referenzstandard besitzt, um einerseits MSE sicher erkennen und andererseits extreme Hypovigilanz objektiv einschätzen zu können.

Abstract

Road accidents are predominantly caused by human factors. Here extreme hypovigilance, sudden attention losses and microsleep episodes (MSE) are notably dangerous. Among technological countermeasures the automatic recognition and prognosis of such spontaneous states plays a major role. Devices actually available at the market are mostly based on contactless measurements of oculomotoric variables, in particular eye-lid variables. In order to validate such devices a laboratory reference standard is needed. The aim of this thesis is to develop, optimize and validate such reference standard.

A review over scientific publications of the last decades offers, that this area is complex and that a comprehensive theory of psychophysiological terms and sequences of states is still under development. It will be explained why electrophysiological signals, like electro-encephalography (EEG) and electro-oculography (EOG), show promise for detection of MSE.

Scoring of MSE based on subject behaviour, in particular before and during MSE, is proposed to be executed by visual observations of several experts. For this purpose video recordings of drivers eyes and of driving scene turned out to be most important resources. Only evident events and evident counter-examples were scored; episodes of unconfident scoring were discarded.

Feature extraction of EEG and of EOG was performed firstly by methods estimating spectral power densities and secondly by a recently introduced state space method, namely the delay-vector variance. Former methods are based on the assumption of linear signals whereas latter is able to parameterize non-linear signal components and also stochasticity. In order to gain minimal empirical classification errors it is shown that exact optimization of temporal location of region of interest, that fusion of many features of all signals and that reduction of correlative features are necessary steps of signal analysis.

Automatic classification has been performed both by simple local and by simple global methods. Furthermore, adaptive methods have been utilized, both with and without regularization of discriminant function. Classifiers utilizing automatically adapting metrics have also been applied in order to extract knowledge automatically. Strongly weighted features have high relevance, because they dominate calculations of distances. Support-Vector Machines (SVM) proved to be most successful in the application domain at hand, if hyper-parameters of several kernel functions were optimized empirically. Mean test errors of 9.8 % were gained for data of 22 subjects.

Leave-One-Out validation which is almost unbiased proved to be efficient in case of SVM despite their relatively high computational load. Hold-Out strategies were applied to data sets of complete experimental nights and of single subjects. Former strategy provides a basis for estimation of temporal stability and latter for validation of independence of subjects. In conclusion, class-related distribution densities turned out to have strong inter-individual differences.

Based on evident MSE examples of single subjects, SVM were adapted, optimized, and subsequently recalled by consecutive data segments. This way, consecutive classification was performed. Their validation was positive. So, our hypothesis was verified that sensor applications based on electrophysiological signals are possible in principle. Results were compared to another team.

In summary, we conclude that the proposed methodology has the capability to establish a laboratory reference standard (gold standard). On the one hand, it is possible to get reliable detections of MSE, and on the other hand, it is possible to judge objectively when subjects are under extreme hypovigilance or not.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Zielstellung	4
1.2	Aufbau der Arbeit	7
2	Hypovigilanz und Mikroschlaf	8
2.1	Definition von Mikroschlaf und extremer Hypovigilanz	8
2.2	Prinzipielle Untersuchungsansätze	11
2.2.1	Leistungstests	12
2.2.2	Mathematische Modellierung der Vigilanzdynamik	12
2.2.3	Erfassung indirekter Messgrößen	13
2.2.4	Erfassung direkter Messgrößen	13
2.3	Elektrophysiologische Untersuchungsansätze	14
2.3.1	Elektroenzephalogramm (EEG)	15
2.3.2	Das Spontan-EEG während des Einschlafvorgangs	16
2.3.3	EEG und Vigilanztests	18
2.3.4	EEG und Schlafdeprivation	19
2.3.5	EOG und Augenbewegungen	20
2.4	Eigener Untersuchungsansatz	21
2.4.1	Befundung	21
2.4.2	Signalaufzeichnung	23
2.4.3	Laborstudie versus Feldstudie	24
2.5	Studienkonzeption und experimentelle Untersuchungen	24
2.5.1	Konzeption der Studien	24
2.5.2	Experimentelle Ausrüstung und Studienaufbau	26
2.5.3	Studie 1	27
2.5.4	Studie 2	29
2.6	Visuelle Befundung	32
2.6.1	Online-Befundung	32
2.6.2	Offline-Befundung	35
2.6.3	Ergebnisse der Befundung	36
2.7	Zusammenfassung	40
3	Grundlagen	41
3.1	Frequenzbereich	41
3.1.1	Diskrete Spektren	42
3.1.2	Kontinuierliche Spektren	46
3.1.3	Steuerung von Verzerrung und Varianz	48
3.1.4	Multi-Taper-Methode (MTM)	51
	Delay-Vektor-Varianz (DVV)	53
3.1.5	Motivation	53
3.1.6	Einführung	54
3.1.7	Schritt 1: Rekonstruktion des Attraktors	56
3.1.8	Schritt 2: Erfassen von Mengen ähnlicher Zustände	58
3.1.9	Schritt 3: Berechnung der Zielvarianzen	59
3.1.10	Das DVV-Diagramm	60
3.1.11	Testen auf Nichtlinearität	62
3.1.12	FT-Surrogate	63
3.1.13	iAAFT-Surrogate	64
3.1.14	Das DVV-Streudiagramm	65
3.1.15	DVV an realen Daten	66
3.1.16	Zusammenfassung	68
3.2	Die Support-Vektor-Maschine	70
3.2.1	Die Maximum-Margin	70
3.2.2	Die Soft-Margin	72
3.2.3	Nichtlineare Trennung mit Kernfunktionen	73
3.3	Lernende Vektorquantisierung	75
3.3.1	Varianten der Lernenden Vektorquantisierung	75
3.3.2	Familie der LVQ-Methoden	78
3.3.3	ES-OLVQ1-Methode	80

3.4	Validation der Klassifikation	82
3.4.1	Trainingsfehler	83
3.4.2	Hold-Out-Methode	84
3.4.3	Kreuzvalidierung und Leave-One-Out	84
4	Prozessstufen der Mustererkennung	86
4.1	Parameteroptimierung für die Klassifikatoren	86
4.1.1	Minkowski-Metriken für Prototypvektorbasierte Klassifikatoren	87
4.2	Der k-Nächste-Nachbarn-Klassifikator	88
4.2.1	kNN: Einfluss verschiedener Minkowski-Metriken	88
4.2.2	kNN: Anzahl der Nachbarn	89
4.3	Die Lernende Vektorquantisierung	91
4.3.1	LVQ: Einfluss verschiedener Minkowski-Metriken	91
4.3.2	LVQ: Anzahl der Prototypvektoren	92
4.3.3	LVQ: Untersuchungen zur Lernschrittweite	93
4.3.4	LVQ: Untersuchung zur Anzahl der Iterationen	95
4.3.5	LVQ: Validierungsmethoden	96
4.4	Support-Vektor-Maschine	97
4.4.1	SVM: Optimierung der Hyperparameter	97
4.4.2	SVM: Validierungsmethoden	99
4.4.3	SVM: Receiver Operating Characteristic	100
4.5	Auswahl geeigneter Parameter für die Vorverarbeitung	102
4.5.1	ROI: Zeitversatz	102
4.5.2	ROI: Segmentlänge	103
4.6	Merkmalsreduktion	104
4.6.1	Anwendung der Hauptkomponentenanalyse	105
4.6.2	Bandmittelungen der konventionellen EEG-Analyse	106
4.6.3	Äquidistante Bandmittelung	108
4.7	Auswahl geeigneter Parameter der Merkmalsextraktion	110
4.7.1	Methoden der Leistungsdichteschätzung	110
4.7.2	Skalierung der Merkmale	111
4.7.3	Delay-Vektor-Varianz	112
4.8	Zusammenfassung	113
5	Ergebnisse	115
5.1	Optimaler Zeitversatz	115
5.2	Variation der NMSE-Beispiele	117
5.3	Vergleich von Klassifikationsverfahren	119
5.4	Fusion von Merkmalen	123
5.5	Automatische Relevanzdetektion	124
5.6	Probandenvalidierung	126
5.7	Retest-Reliabilität	130
5.8	Fortlaufende Klassifikation	133
5.9	Zusammenfassung	136
6	Zusammenfassung und Ausblick	139
Anhang A: MSE- und NMSE-Datenbeispiele		143
Anhang B: Lineare und nichtlineare Zeitreihen		151
Anhang C: Studienübersicht		154
Anhang D: Fortlaufende Klassifikation		155
Anhang E: Software zur Klassifikatoren		157
Anhang F: Ergänzungen zur Spektralschätzung		158
Thesen		159
Abkürzungsverzeichnis		161
Literaturverzeichnis		163
Erklärung		176