

# U-Matrix-Auswertung von Selbstorganisierenden Merkmalskarten für die Clusterung von EEG-Segmenten

David Sommer<sup>1</sup>, Martin Golz<sup>1</sup>, UdoTrutschel<sup>2</sup>  
<sup>1</sup>sommer@informatik.fh-schmalkalden.de

<sup>1</sup>Fachhochschule Schmalkalden, Fachbereich Informatik, PF 182, D-98574 Schmalkalden  
<sup>2</sup>Circadian Technologies Inc., 125 Cambridge Park Drive, Cambridge, MA 02140

## Kurzfassung

In diesem Beitrag werden einige Möglichkeiten zur Auswertung von Selbstorganisierenden Merkmalskarten für die Clusterung multivariater Merkmalsvektoren, die aus selektierten EEG-Segmenten extrahiert wurden, vorgestellt. Da die übliche Auswertung der Gewinnhäufigkeiten in vielen Anwendungsfällen nicht eindeutig und instabil ist und außerdem eine Bewertung schwierig ist, wird zusätzlich die U-Matrix ausgewertet. Mit einem Segmentierungsverfahren aus der Bildverarbeitung, der Wasserscheidentransformation, werden geschlossene Grenzen auf der Merkmalskarte erzeugt. Damit wird eine verbesserte Auswertung der Karte möglich. Es lassen sich in Abhängigkeit von einem Schwellwertparameter die Prototypvektoren gruppieren und die Anzahl der Cluster bestimmen.

## Einleitung

Vielen Menschen werden während der Nachtzeiten entgegen ihrem biorhythmischen Zustand verantwortungsvolle und hohe Aufmerksamkeit erfordern Tätigkeiten abverlangt. Häufig lassen sich Aufmerksamkeitsverluste durch starke Ermüdung oder gar das Aussetzen der unmittelbaren Reaktionsfähigkeit durch Mikroschlafattacken nicht vermeiden [1]. Um wirkungsvolle Ansätze zur Vermeidung solcher Attacken zu erhalten, müssen die Entstehungsbedingungen besser verstanden werden und die Detektion kritischer Aufmerksamkeitszustände sicherer beherrscht werden.

Dabei spielt die Ableitung und Auswertung des Elektroenzephalogramms (EEG) eine wichtige Rolle, da es zur Zeit zu den wichtigsten Signalen zählt, um ein funktionelles Abbild des Zentralen Nervensystems zu erhalten.

Für die Prognose und Detektion von Mikroschlafattacken ist der Augenbereich besonders interessant, da auffällige Vorboten beobachtet werden können [2]: starre Augen, Lidschlagsequenzen, geringe Lidöffnung, verlängerte Lidschlüsse, Fluktuationen des Pupillendurchmessers und willkürliche langsame zyklische Augenbewegungen. Diese langsamen Augenbewegungen (SEM = Slow Eye Movement) haben eine Periodendauer von etwa vier Sekunden. Sie treten nicht vor jeder Attacke und nicht bei jedem Individuum auf, gelten jedoch als ein sicheres

Einschlafzeichen und werden oft noch mehrere Minuten nach dem Einschlafen durch Ableitung des Elektrookkulogramms (EOG) gemessen. Bereits beim Auftreten der Mikroschlaf-Vorboten müssen sich offensichtlich Teile des Wahrnehmungs- und des kognitiven Systems in einem anderen funktionellen Zustand befinden, der sich wiederum im EEG niederschlagen sollte.

Die Relevanz der EEG- und EOG-Messungen für die Einschätzung der Ermüdung und des Mikroschlafrisikos wurde mittlerweile durch mehrere Studien belegt [3,4,5]. Ein Überblick über die Ergebnisse mehrerer Forschungsgruppen ist in [6] zu finden. Bereits Davis et al. [7] beobachteten, daß sich die Verteilung des EEGs sowohl in der Amplitude als auch in den Frequenzen und in der spatialen Lokalisation beim Übergang vom wachen in den schlafenden Zustand ändert. Diese Veränderungen sind jedoch komplex und interindividuell sehr verschieden [6]. Einige Autoren berichteten über ansteigende spektrale Leistungsdichten im Alphaband (7,5 - 12,5 Hz) bei zunehmender Müdigkeit [8] und, falls SEMs auftreten, auch über ein Ansteigen im Thetaband (3,5 - 7,5 Hz) [9,10]. Dennoch ist es für EEG-Experten schwierig und zeitaufwendig, Mikroschlafattacken zu befunden. Die Abweichungen zwischen den Einschätzungen der Experten sind beträchtlich [11]. Die Analyse erfolgt oft nur auf Schwellwertüberschreitungen der einzelnen spektralen Komponenten oder gar nur auf eine visuelle Analyse des Zeitbereichssignals hinaus. Falls multivariate Analysen erstellt werden, unterliegen ihnen meist nur lineare Modelle. Mit der Anwendung von Neuronalen Netzen könnte es möglich sein, die Verteilungsdichten der Merkmale ohne zusätzliche Experteninformationen - also unüberwacht - und nichtlinear zu analysieren. Daraus lassen sich unter Umständen Aussagen über die Anzahl möglicher Cluster, die Ausprägungen der spektralen Leistungsdichten des EEGs und die Stabilität der Cluster treffen.

## Experimente

11 Personen (3 weibliche, 8 männliche) im Alter zwischen 20 und 40 Jahren fuhren auf einem Fahrsimulator in den Nachtstunden zwischen 1 und 8 Uhr in mehreren 25 minütigen Abschnitten [12]. Es wurde das EEG und das EOG aufgezeichnet und mit einer Rate von 128 Hz abgetastet. Um die langsamen Augenbewegungen automatisch zu finden, wurde das EOG-Signal mit einem 8 s langem, zwei Perioden umfassenden Sinussignal korreliert. Falls die Kreuzkorrelationsfunktion dreimal hintereinander einen Schwellwert überschreitet, der zuvor an visuell ausgewählten Beispielen bestimmt wurde, konnte ein SEM- Ereignis angenommen werden. Vom EEG-Segment der vorangegangenen zwei Sekunden wurden dann die relativen spektralen Leistungsdichten im Frequenzbereich zwischen 0,5 Hz und 23,5 Hz mit einer Frequenzauflösung von 0,5 Hz berechnet.

## Clusterung der EEG-Segmente

Die so erhaltenen 47 Spektralkomponenten bildeten die Merkmalsvektoren für die nachfolgenden Analysen. Mit einer Hauptkomponenten-Analyse wurde routinemäßig untersucht, ob die Merkmalsvektoren in einem linearen Unterraum liegen. Dafür gab es keine Hinweise. Schon bei Elimination der drei kleinsten der 47 Hauptkomponenten lag die Restvarianz bereits bei 5%.

Für das Training der Selbstorganisierenden Merkmalskarten (SOM) [13] wurden deshalb die 47-dimensionalen Merkmalsvektoren verwendet. SOM zählt zu den prototypvektorbasierten Netzen. Mit Prinzipien des Wettbewerbslernens wird eine Anpassung der Gewichtsvektoren an die Verteilung der Eingabevektoren angestrebt. Als Ähnlichkeitsmaß wurde die euklidische Norm

des Differenzvektors von Merkmalsvektor  $\mathbf{x}$  und Gewichtsvektor  $\mathbf{w}$  verwendet, so daß die Gewichtsvektoren nach folgender Beziehung verändert werden:

$$\Delta \mathbf{w}_j(t) = \eta(t) h_{cj}(t) [\mathbf{x}(t) - \mathbf{w}_j(t)] \quad (1)$$

Wobei  $\eta(t)$  eine mit steigendem Iterationsindex  $t$  kleiner werdende Schrittweite ist und  $h_{cj}(t)$  die Nachbarschaftsfunktion zwischen dem Gewinner des Wettbewerbs  $\mathbf{w}_c$  und dem Gewichtsvektor  $\mathbf{w}_j$  ist. Mit zunehmendem Iterationsindex nimmt auch die Höhe und der Radius der Nachbarschaftsfunktion ab; die Nachbarschaftsbeziehungen dagegen sind durch eine topologische Struktur, bspw. ein zweidimensionales tetragonales Gitter, fest definiert und ändern sich nicht. In der letzten Phase des Trainings, der sogenannten Feinordnungsphase [14], ist der Nachbarschaftsradius sehr klein, so daß nur noch der Gewichtsvektor  $\mathbf{w}_c$  des Gewinnerneurons und eventuell seine unmittelbaren Nachbarn verändert werden.

Für den Fall der eindimensionalen Karte läßt sich ableiten [14], daß mit dem Trainingsgesetz (1) eine monotone Funktion der Verteilungsdichte der Merkmalsvektoren approximiert wird. Im Falle von zweidimensionalen Karten wird ein Kompromiß zwischen Dichteapproximation und Minimierung des mittleren quadratischen Fehlers der Vektorquantisierung gefunden [15].

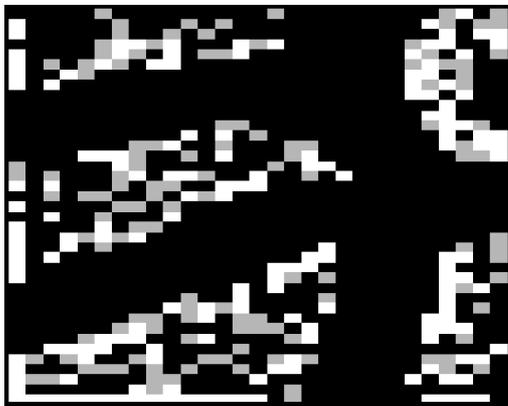


Abb.1a) Relative Gewinnhäufigkeiten einer SOM-Karte mit 30x40 Neuronen für Gauß-Mixtur-Daten.

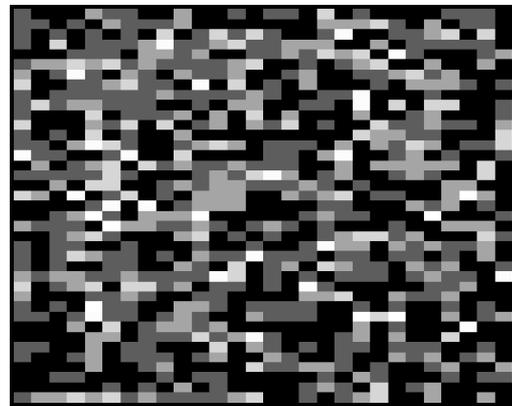


Abb.1b) Relative Gewinnhäufigkeiten einer SOM-Karte mit 30x40 Neuronen für SEM-EEG-Daten

Falls sich viele Merkmalsvektoren in einer kompakten Region befinden und möglichst noch Dichtezentren existieren, wie sie bspw. bei Gauß-Mixturen auftreten, dann läßt sich die Karte gut anhand der relativen Gewinnhäufigkeiten der einzelnen Neuronen auswerten. Abb.1a zeigt eine solche Gewinnverteilung, in der sich ohne Probleme fünf Gebiete mit erhöhter Gewinnhäufigkeit feststellen lassen. Die Daten hierzu wurden künstlich erzeugt, in dem fünf Cluster mit Normalverteilung im 47-dimensionalen Raum mit unterschiedlicher Lage der Dichtezentren und unterschiedlichen Kovarianzmatrizen erzeugt wurden. Dieser Verteilungsdichtetyp soll als Gauß-Mixtur bezeichnet werden. Die schwarz gefärbten Topologieknoten in Abb.1a sind niemals gewinnende Neuronen (tote Neuronen), die häufig das Feststellen von clustertrennenden Regionen erleichtern.

Abb.1b dagegen zeigt die Verteilung der relativen Gewinnhäufigkeiten für die experimentell erhaltenen Merkmalsvektoren. Eine Abgrenzung von Gebieten mit erhöhter Gewinnhäufigkeit ist hier nicht möglich. In der trainierten SOM befinden sich jedoch noch eine Fülle weiterer Informationen. Beispielsweise läßt sich der Abstand topologisch benachbarter Gewichtsvektoren auswerten. Für den Fall, daß nach dem Training keine topologischen Defekte mehr existieren [16], sind diese Gewichtsvektoren auch im Merkmalsraum benachbart. Ist zusätzlich ihr Abstand klein, dann repräsentieren sie vermutlich gemeinsam Merkmalsvektoren eines Clusters. Ist ihr Abstand vergleichsweise groß, dann repräsentieren sie vermutlich unterschiedliche Cluster. Die Visualisierung der Gewichtsvektor-Abstände wurde von Ultzsch unter dem Namen Unified-

Distance-Matrix (U-Matrix) eingeführt [17]. Zur Berechnung der U-Matrix eignet sich eine zwei-dimensionale tetragonale Topologie mit  $n_x$  Spalten und  $n_y$  Zeilen. Für jeden Gewichtsvektor  $\mathbf{w}_{x,y}$ , wobei  $x$  und  $y$  die Indexe auf der topologischen Struktur sind, werden die euklidischen Abstände  $dx$  und  $dy$  zu den zwei topologischen Nachbarn in  $x$ - und  $y$ -Richtung und der Abstand  $dxy$  zum übernächsten Nachbarn bestimmt:

$$dx(x,y) = \|\mathbf{w}_{x,y} - \mathbf{w}_{x+1,y}\| \qquad dy(x,y) = \|\mathbf{w}_{x,y} - \mathbf{w}_{x,y+1}\|$$

$$dxy(x,y) = \frac{1}{2} \left( \frac{\|\mathbf{w}_{x,y} - \mathbf{w}_{x+1,y+1}\|}{\sqrt{2}} + \frac{\|\mathbf{w}_{x,y+1} - \mathbf{w}_{x+1,y}\|}{\sqrt{2}} \right)$$

Der Abstand  $du$  wird durch Berechnung des Mittelwertes der acht umgebenden Abstände gebildet. Mit den vier Abständen je Neuron  $dx$ ,  $dy$ ,  $dxy$  und  $du$  läßt sich die Matrix  $\mathbf{U}$  bilden, die das Format  $(2n_x - 1) \times (2n_y - 1)$  hat.

$$\mathbf{U} = \begin{bmatrix} du(1,1) & dx(1,1) & du(2,1) & \dots & du(n_x,1) \\ dy(1,1) & dxy(1,1) & dy(2,1) & \dots & dy(n_x,1) \\ du(1,2) & dx(1,2) & du(2,2) & \dots & du(n_x,2) \\ dy(1,2) & dxy(1,2) & dy(2,2) & \dots & dy(n_x,2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ du(1,n_y) & dx(1,n_y) & du(2,n_y) & \dots & du(n_x,n_y) \end{bmatrix}$$

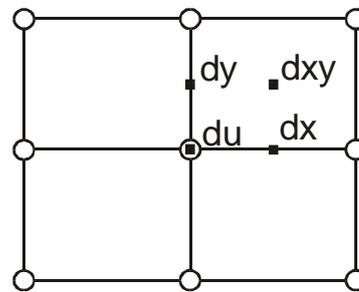


Abb.2 Definition der U-Matrix und Lokalisation der Stützstellen für ihre Elemente auf der tetragonalen topologischen Struktur. Es werden nur die Stützstellen für das Neuron in der Bildmitte gezeigt. Kreise: Neuronenpositionen; schwarze Quadrate: Stützstellenpositionen

In Abb.2 ist gezeigt, wie die einzelnen Elemente der U-Matrix auf der topologischen Struktur als Stützstellen für zweidimensionale Interpolationsverfahren dienen. Die Abstände lassen sich dann als kontinuierliche zweidimensionale Funktion darstellen, wobei der Funktionswert auf eine Grauwertskala abgebildet wird. Helle Grautöne bilden kleine Abstände ab und dunkle Grautöne große Abstände.

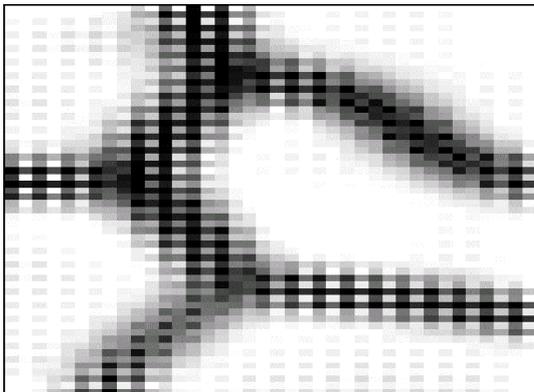


Abb.3a) U-Matrix der SOM-Karte aus Abb.1a

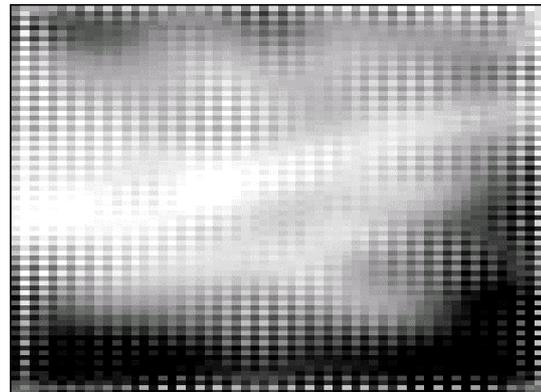


Abb.3b) U-Matrix der SOM-Karte aus Abb.1b

Die U-Matrix hat wie die relativen Gewinnhäufigkeiten nur bei gut separablen Gauß-Mixturen einfach zu überschauende Ausprägungen. In Abb.3a ist die U-Matrix der gleichen Daten, die in Abb.1a eingesetzt wurden, dargestellt. Deutlich sind die Clusterregionen auf der Karte als Gebiete mit kleinen Abständen zwischen den Gewichtsvektoren zu sehen, die durch kleine Regionen mit hohen Abständen untereinander getrennt werden. Für die experimentell erhaltenen Daten (Abb.3b) ist die Ausprägung der U-Matrix komplizierter. Eine klare Abgrenzung von Regionen mit kleinen Abständen bereitet Probleme.

Von Costa et al. [18] wurde zur automatischen Segmentierung der U-Matrix ein aus der Bildverarbeitung bekanntes Verfahren, die Wasserscheidentransformation [19], vorgeschlagen. Die U-Matrix wird hierbei als Grauwertgebirge betrachtet. Gewichtsvektoren, deren Abstände im Merkmalsraum vergleichsweise groß sind, werden durch hellere Farben bzw. Bergspitzen dargestellt. Das Verfahren der Wasserscheidentransformation kann mit Wassertropfen veranschaulicht werden, die auf das Grauwertgebirge fallen und den regionalen Minima entgegenstreben, somit entstehen verschiedene geflutete Regionen (Abb.4a). Wasserscheiden werden an den Stellen errichtet, wo diese Regionen zusammenfließen würden.

Die durch Wasserscheidenlinien gebildeten Segmente der U-Matrix geben nun Auskunft über die Anzahl der gefundenen Cluster und über die Neuronen, die gemeinsam ein Cluster repräsentieren. Über ihre Gewichtsvektoren wird das Cluster als Verschmelzung der Voronoi-Mengen gebildet. Die Bestimmung der Minima ist problematisch und führt schnell zur Übersegmentierung der U-Matrix [18]. Durch einen Schwellwertparameter  $h_{\min}$  kann die Anzahl der gefundenen lokalen Minima der U-Matrix während der Initialisierung der Segmentierung verringert werden, indem alle Grauwerte, die kleiner als  $h_{\min}$  sind, gleich  $h_{\min}$  gesetzt werden.

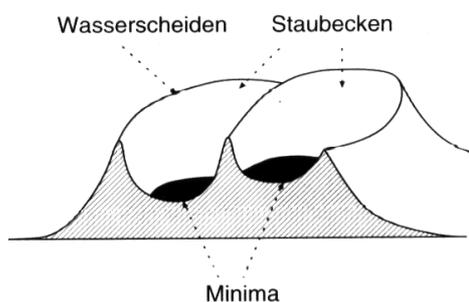


Abb.4a Schnitt durch ein Grauwertgebirge

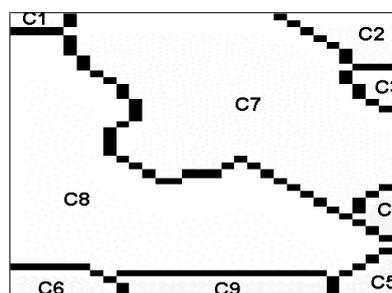


Abb.4b U-Matrix aus Abb.3b nach einer Wasserscheidentransformation

## Ergebnisse

Das entscheidende Ergebnis des Clusterverfahrens ist in Abb.4b zu sehen. Neun unterschiedlich große Bereiche auf der SOM-Karte stellen die gefundenen Cluster dar. Die Merkmalsvektoren der Cluster sind in Abb.5a zu sehen. Die Cluster 1 und 2 enthalten Merkmalsvektoren mit starken Ausprägungen im Alpha-1-Band (7,5 - 10,5 Hz), Cluster 6 im Alpha-2-Band (10,5 - 12,5 Hz), Cluster 3 im Thetaband (3,5 - 7,5 Hz) und Cluster 9 im Deltaband (1,0 - 3,5 Hz). Im Gegensatz zu den bisher üblichen bandgemittelten Analysen erhält man genauere Unterscheidungen der Ausprägungen. Beispielsweise sind die Merkmalsvektoren von Cluster 1 und 2 im gleichen Spektralband maximal, sie unterscheiden sich jedoch durch unterschiedliche Ausprägungen in den anderen Spektralbereichen. Visuell sind die gefundenen Cluster anhand von Abb.5a gut nachvollziehbar.

Die Segmentierungsergebnisse der Wasserscheidentransformation sind abhängig von der Größe der SOM. Bei relativ großer Neuronenzahl ergeben sich relativ viele Cluster. Eine Glättung der Grauwertfunktion mit einem zweidimensionalen Filter verringert die Gefahr einer zu starken Übersegmentierung. Außerdem sind in einigen Regionen der gezeigten U-Matrizen (Abb.3a, 3b) schwarz-weiße Texturen zu erkennen, die Ausdruck von relativ großen Unterschieden zwischen  $dx$  und  $dy$  sind. Offensichtlich kommt es zu lokalen Dehnungen bzw. Stauchungen der SOM entlang einer topologischen Richtung. Die näheren Umstände sind Gegenstand weiterer Untersuchungen. Visualisiert man nicht alle Elemente der U-Matrix, sondern bspw. nur die  $dx$ -Werte, dann verschwinden einige Segmentgrenzen. Wir haben vorerst folgende Vorgaben gewählt:

- Ausschließliche Verwendung der Funktion  $du(x,y)$
- Glättung mit 3x3-Filter
- Segmentierung mit Wasserscheidentransformation

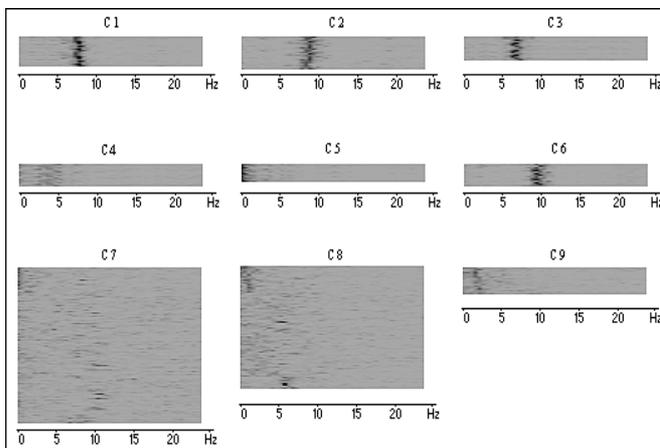


Abb.5a Wasserfalldiagramm der geclusterten Merkmalsvektoren. In horizontaler Richtung sind die Merkmale aufgetragen, die rel. spektralen Leistungsdichten sind als Graustufen dargestellt.

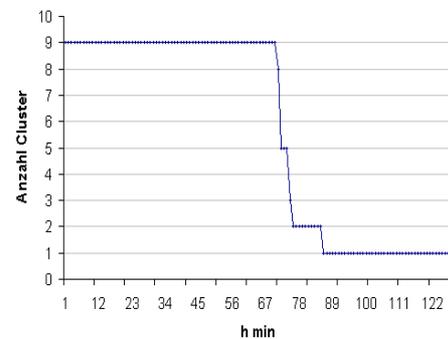


Abb.5b Anzahl der Cluster in Abhängigkeit von  $h_{min}$  für U-Matrix aus Abb.3b

Die Segmentierung wurde mit steigendem Schwellwertparameter  $h_{min}$ , wie in Costa et al. [18] beschrieben, mehrfach wiederholt. Dabei ergaben sich zwei Plateaus in der Funktion  $n_{Cluster} = f(h_{min})$  (Abb. 5b). Das Plateau für  $n_{Cluster} = 9$  war am stärksten ausgeprägt. Abb.5a bestätigt, daß die Aufteilung  $n_{Cluster} = 2$  zu grob ist.

## Zusammenfassung

Die hier vorliegenden 47-dimensionalen Merkmalsvektoren konnten mit den Selbstorganisierenden Merkmalskarten in neun verschiedene Cluster gruppiert werden. Die Auswertung der SOM erfolgte über die U-Matrix, die mit der Wasserscheidentransformation segmentiert wurde. Dadurch erhält man objektive und reproduzierbare Clusterungen.

Eine umfassende Validierung dieser ersten Resultate steht noch aus. Es ergaben sich jedoch deutliche Hinweise, daß vor den Slow Eye Movements nicht nur erhöhte Alphaleistungen (Alpha-Bursts) im EEG festzustellen sind, sondern daß in einer Vielzahl von Fällen Aktivitäten in anderen EEG-Spektralbändern auftreten. Mit der vorgestellten Methode ist eine detaillierte Analyse möglich.

## Referenzen

- [1] Moore-Ede,M.; The twenty-four hour society - understanding human limits in a world that never stops; Addison-Wesley, Reading,MA; 1993
- [2] Trutschel, U.; Guttkuhn, R.; Ramsthaler, C.; Golz, M.; Moore-Ede, M.; Automatic detection of micro-sleep events using a neuro-fuzzy hybrid system; Proceedings of the Eufit'98; Aachen; 1998, 1762-1766
- [3] O'Hanlon, JF; Kelly, GR; Comparison of performance and physiological changes between drivers who perform well and poorly during prolonged vehicular operation; in Mackie, RR(ed.); Vigilance: theory, operational performance and physiological correlates; Plenum Press, New York, 1976, 87-109
- [4] Brookhuis, K.A. et al., EEG energy spectra and driving performance under the influence of some antidepressant drugs; in O'Hanlon, JF; de Gier, JJ (eds.): drugs and driving; Taylor and Francis, London, 1986, 213-221
- [5] DeWaard, D.; Brookhuis, KA; Assessing driver status: a demonstration experiment on the road; *Accid. Anal. Prev.*, 23, 1991, 297-307
- [6] Santamaria,J.; Chiappa,K.H.; The EEG of drowsiness in normal adults; *J Clin. Neurophysiol.* 4 (1987), 327-382
- [7] Davis,H.; Davis,P.A.; Loomis,A.L.; Harvey,E.N., Hobart,G.; Human brain potentials during the onset of sleep; *J. Neurophysiol.* 1 (1938), 24-38
- [8] Torsvall,L.; Akerstedt,T.; Sleepiness on the job:continously measured EEG changes in train drivers; *Electroencephalography and clinical Neurophysiology*, 66 (1987), 502-511
- [9] Torsvall,L.; Akerstedt,T.; Eye closure, sleepiness and EEG spectra; in: Koella,W.P. et al.(Eds.); *Sleep 1984*; Fischer, Stuttgart;
- [10] Akerstedt,T.; Torsval,L.; Gillberg,M.; Ambulatory measurement of sleepiness; in: Leonard,A.(Ed.); *Vigilance: methods, modus and regulation*; Lang, Frankfurt; 1988
- [11] Kelley.J.T.; Reed,K.; Reilly,E.L.; Overall,J.E.; Reliability of rapid clinical staging of all-night sleep EEG; *Clin. Electroenceph.*; 16,1(1985), 16-20
- [12] Ramsthaler, C.; Charakterisierung und Erkennung von Mikroschlafepisoden mit neuroinformatischen Methoden; Diplomarbeit; FH Schmalkalden; 1998
- [13] Kohonen, T.; Self-organized formation of topologically correct feature maps; *Biol. Cybernet.*, 43 (1982), 59-69
- [14] Kohonen, T.; *Self- Organizing Maps*; Springer, Berlin, 1995
- [15] Fritzke, B.; Wachsende Zellstrukturen - ein selbstorganisierendes neuronales Netzwerkmodell; Dissertation, Uni Erlangen-Nürnberg, 1992
- [16] Villmann, T.; Topologieerhaltung in selbstorganisierenden neuronalen Merkmalskarten; Dissertation, Uni Leipzig, 1996
- [17] Ultsch, A. & H.P. Siemon; *Exploratory Data Analysis: Using Kohonen Networks on Transputers*; Univ. of Dortmund, Technical Report 329, Dortmund, Dec. 1989
- [18] Costa, Netto; Automatic data classification by a hierarchy of self-organizing maps; *InProc. of the IEEE*, 1999
- [19] Vincent, L.; Soille, P.; Watersheds in Digital Spaces: An Efficient Algorithm Based on Immersion Simulation; *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 1991