

**Eine Methode zur Entdeckung von
komplexen Mustern in Zeitreihen mit
Neuronalen Netzen und deren
Überführung in eine symbolische
Wissensrepräsentation**

**Dissertation
zur
Erlangung des Doktorgrades
der Naturwissenschaften
(Dr. rer. nat.)**

**dem Fachbereich Mathematik der
Philipps-Universität Marburg
vorgelegt von**

**Gabriela Dick de Sousa Guimarães
aus Porto (Portugal)**

Marburg/Lahn 1998

Vom Fachbereich Mathematik
der Philipps-Universität Marburg
als Dissertation am 4.5.1998 angenommen.

Erstgutachter: Prof. Dr. Alfred Ultsch

Zweitgutachter: Prof. Dr. Wolfgang Urfer

Tag der mündlichen Prüfung am 18.5.1998

Inhaltsverzeichnis

Kapitel 1	Einleitung	5
	1.1 Ziele der Arbeit	7
	1.2 Überblick	9
Kapitel 2	Grundlagen	11
	2.1 Selbstorganisierende Merkmalskarten (SOM)	13
	2.2 Hybride Systeme	21
	2.3 Mustererkennung und Mustererkennungssysteme	27
Kapitel 3	Eine Methode zur temporalen Wissenskonzersion (TWK)	33
	3.1 Grundlegende Begriffe	34
	3.2 Überblick über die Methode	48
	3.3 Schritte der TWK	54
	3.4 Gewinnung von temporalen Grammatiken (TG)	63
Kapitel 4	Selbstorganisierende Merkmalskarten zur temporalen Wissenskonzersion	73
	4.1 Vorverarbeitung mit Selbstorganisierenden Merkmalskarten .	74
	4.2 U-Matrizen zur Erkennung von PrimitivePatterns und Events	76
	4.3 Wege auf U-Matrizen zur Visualisierung von Successions und TemporalPatterns	79

Kapitel 5	Temporale Wissenskonzersion für schlafbezogene Atmungsstörungen	83
	5.1 Schlafbezogene Atmungsstörungen (SBAS)	84
	5.2 Erkennung und Beschreibung von SBAS durch die TWK	89
	5.3 Evaluation der Ergebnisse der TWK angewandt auf SBAS ..	124
Kapitel 6	Diskussion	149
	6.1 Selbstorganisierende Merkmalskarten (SOM) zur Verarbeitung von Zeit	150
	6.2 Symbolische Wissensrepräsentationen für Zeitreihen	163
	6.3 Hybride Systeme und temporale Wissenskonzersion	170
Kapitel 7	Zusammenfassung und Ausblick	175
Anhang	179
Glossar	215
Index	227
Abbildungserzeichnis	233
Tabellenverzeichnis	237
Literaturverzeichnis	239

Kapitel 1

Einleitung

Als Folge der Entwicklung immer leistungsfähigerer Rechner in den letzten Jahren konnten zunehmend immer größere Datenmengen digital erfaßt werden. Beispiele hierfür sind bei einem industriellen Prozeß on-line erfaßte Daten oder über einen längeren Zeitraum registrierte medizinische Daten oder Daten, die durch Satelliten oder andere Meßverfahren gesammelt worden sind. Von den meist großen Datensammlungen erhofft man sich u.a. eine Verbesserung von Diagnose und Steuerung zugrundeliegender komplexer Prozesse. Ein besonderes Problem stellen dabei Datenanalyse und Datenauswertung dar. Hierzu werden überwiegend Verfahren aus Statistik oder Signalverarbeitung eingesetzt. Um die Auswertemöglichkeiten zu verbessern, können moderne Ansätze wie z.B. Technologien der Künstlichen Intelligenz (KI) und Künstliche Neuronale Netze (KNN) eingesetzt werden [Puppe 91].

Ein wesentlicher Vorteil von Expertensystemen liegt darin, daß sie nicht nur als Entscheider eingesetzt werden können, sondern daß sie auch die durch eine Inferenzkomponente eines Expertensystems gezogenen Schlußfolgerungen erklären können. Expertensysteme benötigen jedoch symbolisch repräsentiertes Wissen, z.B. in Form von Regeln. Die Erfassung solchen Wissens (Wissensakquisition) ist eine schwierige Aufgabe. Durch den Prozeß der Wissensakquisition soll Expertenwissen derart erfaßt werden, daß es zum einen z.B. durch Expertensysteme maschinell weiterverarbeitet werden kann, und daß es zum anderen möglichst umfassend und vollständig ist. Wissensakquisition ist häufig ein langwieriger Prozeß, bei dem das Expertenwissen in vielen Gesprächsrunden ermittelt wird. Selten können dabei Experten für die Konstruktion von Expertensystemen von ihren Aufgaben freigestellt werden. Selbst wenn dies der Fall wäre, so ist doch das aus Erfahrung gewonnene Wissen häufig nur schwer kommunizierbar und in regel-

haftes Wissen überführbar, weil nicht nur Regelmäßigkeiten vollständig und exakt zu beschreiben sind, sondern weil auch alle möglichen Spezialfälle wie z.B. Ausnahmen, Sonderfälle, Grenzfälle korrekt abgehandelt werden müssen.

In der Arbeitsgruppe von Prof. A. Ultsch wird seit einigen Jahren die Problemstellung Wissensakquisition untersucht. Es sind Methoden entwickelt worden, die durch eine geeignete Kombination von KNN und Regelgenerierungsalgorithmen eine automatische Wissensakquisition möglich machen [Ultsch92, Ultsch 93a]. Ausgangspunkt sind die aus einer Anwendung stammenden Datensammlungen. KNN eignen sich zur Wissensakquisition, da sie aus Beispielen lernen können. Außerdem sind KNN in der Lage mit inkonsistenten, unvollständigen und widersprüchlichen Daten, wie sie in großen Datensammlungen vorkommen, umzugehen. Wird nach unbekanntem Zusammenhängen gesucht bzw. ist nur wenig Wissen über den zu untersuchenden Prozeß vorhanden, so eignen sich zur Wissensakquisition spezielle KNN, die sich mit ihrer Fähigkeit zur Selbstorganisation an die Strukturen von Daten anpassen. Die Anpassung der internen Netzstrukturen an die Strukturen der Daten erfolgt in ähnlicher Weise wie bei den senso-motorischen Feldern des Gehirns, die auf wichtige Reize der Außenwelt zu reagieren lernen. So liegen z.B. sensorische Felder, die die Tastreize des Gesichts verarbeiten, im Gehirn in einer räumlichen Anordnung vor, die auch der Anordnung der Gesichtszüge entspricht. Diese Anordnung wird erst im Laufe der ersten Lebensjahre durch Ähnlichkeit benachbarter Reize gelernt [Lemon 88]. Falls hier viele Berührungsreize stattfinden, bilden sich überproportional große Areale aus. Sog. selbstorganisierende Merkmalskarten (SOM) nach dem Modell von Kohonen (1984) funktionieren nach einem ähnlichen Organisationsprinzip. Durch SOM wird eine Abbildung von Daten in einem hochdimensionalen Raum auf eine in der Regel zweidimensionale Neuronenschicht (topographische Merkmalskarte) erzeugt derart, daß besondere Eigenschaften der Daten des hochdimensionalen Raumes (Nachbarschaft und Dichte) auf der Merkmalskarte so getreu wie möglich wiedergegeben werden. Ein wesentlicher Nachteil von KNN ist jedoch, daß sie Entscheidungen nicht begründen oder erklären können.

Durch Integration von KNN und wissensbasierten Systemen können die eben genannten Nachteile beider Technologien behoben werden, indem die Vorteile beider Ansätze wie z.B. Lernfähigkeit, Verarbeitung von fehlerhaften und widersprüchlichen Daten bei KNN und die Erklärungsfähigkeit von wissensbasierten Systemen genutzt werden. In KNN ist Wissen in einer subsymbolischen Form repräsentiert, wobei das zu repräsentierende Symbol auf einer Vielzahl von Einheiten (Neuronen, Gewichte) aufgeteilt wird. In Technologien der KI liegt das zu repräsentierende Wissen in einer symbolischen Form vor, z.B. in einer für Menschen verständlichen, regelhaften Form. Ein Übergang zwischen beiden Wissens-

repräsentationsformen wird in Ultsch (1996) als Wissenskonversion bezeichnet. Als eine Form der Wissenskonversion wird z.B. eine automatische Wissensakquisition durch Integration von KNN und Regelgenerierungsalgorithmen angesehen.

Bisherige Ansätze für eine Wissenskonversion [Ultsch 91] gehen von Daten aus, die keine zeitlichen Abhängigkeiten untereinander aufweisen. Eine neuartige Qualität der Wissenskonversion resultiert aus der Einbeziehung von Zeitreihen. In dieser Arbeit wird eine Methode zur Überführung von Zeitreihen in eine temporale, symbolische Wissensrepräsentation entwickelt, die auf ein real existierendes Anwendungsbeispiel aus der Medizin angewendet wird.

1.1 Ziele der Arbeit

Es ist wesentliches Ziel dieser Arbeit, eine "Brücke" zwischen Zeitreihen und einer temporalen, symbolischen Wissensrepräsentation für komplexe Muster in Zeitreihen zu schlagen. Hierzu werden durch die hier entwickelte Methode verschiedene Abstraktionsebenen eingeführt, so daß ein Übergang in eine symbolische Wissensrepräsentation durch eine zunehmende, "gleitende" Wissenskonversion aus Zeitreihen erfolgt. Das bedeutet, daß eine Überführung in eine symbolische Wissensrepräsentation nicht ad-hoc, sondern in einzelnen kleinen Schritten realisiert wird. Durch dieses schrittweise Vorgehen wird ein im Prinzip sehr schwieriges Problem in einzelne technisch lösbare Teilaufgaben zerlegt.

Es wird der Frage nachgegangen, inwiefern selbstorganisierende Merkmalskarten (SOM) nach dem Modell von Kohonen (1984) zur Erkennung von Strukturen in Zeitreihen eingesetzt werden können. Dabei haben sich die U-Matrix-Methoden [Ultsch 92] als ein mächtiges Werkzeug zur Erkennung von Strukturen in hochdimensionalen Daten herausgestellt, durch die angelernte Netzstrukturen visualisiert werden können. Die Erzeugung einer computergraphischen Darstellung von hochdimensionalen Daten z.B. durch U-Matrizen wird als wesentlicher Bestandteil einer Strukturanalyse aufgefaßt. In dieser Arbeit wird untersucht, wie zeitliche Verläufe auf U-Matrizen beobachtet und interpretiert werden können. Weil Zeitreihen auf verschiedenen Abstraktionsebenen beschrieben werden, werden Überlegungen zur Realisierung von hierarchischen SOM angestellt. Die Beobachtung von zeitlichen Verläufen auf U-Matrizen erfolgt damit auf verschiedenen Ebenen.

Ein weiteres Ziel ist die Entwicklung einer adäquaten Repräsentation für temporales Wissen, das in einer für Menschen verständlichen Form dargestellt werden soll. Die sprachliche Form wird als die meist verbreiteste und natürlichste Darstellung für Wissen angesehen [Bibel et al. 93], die deutliche Vorteile gegenüber anderen Repräsentationsformen bzgl. Kommunikation, Verständlichkeit und Interpretation aufzeigt. In dieser Arbeit wird eine sprachliche Repräsentation für Zeitreihen in Form einer formalen Grammatik verwendet.

Grundlage für die Erzeugung einer solchen Grammatik aus Zeitreihen sind die auf verschiedenen Abstraktionsebenen durch eine Strukturanalyse bestimmten Zwischenergebnisse. Zur Gewinnung einer für die Anwendung ggf. bedeutungsvollen Beschreibung der entdeckten Strukturen wird der Einsatz von Regelgenerierungsalgorithmen untersucht. Es wird gezeigt, daß auf einer nicht zeitbezogenen Ebene die durch einen Regelgenerierungsalgorithmus erzeugten Regeln eine inhaltliche Beschreibung von Strukturen in Zeitreihen liefern können.

Ein weiteres Ziel ist es, die hier entwickelte Methode auf ein real existierendes Anwendungsbeispiel anzuwenden. Hierzu wurde als Beispiel eine Anwendung aus der Medizin, schlafbezogene Atmungsstörungen (SBAS), ausgewählt. Es handelt sich um ein ausreichend komplexes Problem, da für mehrere Patienten über einen Zeitraum hinweg eine große Anzahl an Zeitreihen gemessen werden. Die Erkennung von verschiedenen Typen von SBAS (Apnoen und Hypopnoen) ist durch die Erkennung von Mustern in atmungsbezogenen Signalen möglich, die durch die kardiorespiratorische Polysomnographie (PSG) aufgezeichnet werden [Penzel 95]. Die verschiedenen Typen manifestieren sich durch unterschiedliche Muster von SBAS und können bei einem Patienten in Kombination vorliegen. Erst eine parallele Auswertung von Zeitreihen der PSG erlaubt eine sichere Unterscheidung aller unterschiedlichen Typen von SBAS. Die Auswertung der PSG ist sehr aufwendig und schwierig, da Patienten sehr unterschiedliche individuelle Krankheitsmuster haben können [Penzel et al. 91]. Ein zusätzliches Problem bei der Erkennung von SBAS liegt in der stark schwankenden Dauer einzelner Schlafapnoen.

Um die Ergebnisse der TWK angewandt auf SBAS evaluieren zu können, wird in dieser Arbeit vorgeschlagen, eine qualitative Evaluation durch eine Expertenbefragung durchzuführen. Hierzu wird ein Fragebogen erstellt.

1.2 Überblick

In *Kapitel 2* werden Grundlagen für die im Rahmen dieser Arbeit entwickelten Methode eingeführt, die im wesentlichen aus dem Gebiet der Künstlichen Intelligenz (KI) und der Künstlichen Neuronalen Netze (KNN) und zum Teil aus der Mustererkennung stammen. Es werden die Grundlagen von selbstorganisierenden Merkmalskarten eingeführt, die im Zusammenhang mit den U-Matrix-Methoden zur Strukturanalyse eingesetzt werden können. Da eine Überführung in eine symbolische Wissensrepräsentation durch die Methode zur temporalen Wissenskonversion erfolgen soll, werden als nächstes grundlegende Begriffe wie z.B. subsymbolische und symbolische Wissensrepräsentation und Grundlagen von hybriden Systemen eingeführt. Von besonderem Interesse sind hier hybride Systeme, bei denen eine Wissenskonversion stattfindet. Letzendlich werden grundlegende Begriffe aus der Mustererkennung eingeführt sowie ein Überblick über verschiedene Methoden der Mustererkennung gegeben.

In *Kapitel 3* wird die hier entwickelte Methode zur temporalen Wissenskonversion (TWK) vorgestellt, durch die eine Überführung von komplexen Mustern in multivariaten Zeitreihen in eine für Menschen verständliche, symbolische Wissensrepräsentation möglich ist. Da durch diese Methode mehrere hierarchische Abstraktionsebenen eingeführt werden, werden zunächst grundlegende Begriffe für die verschiedenen Abstraktionsebenen eingeführt. Anhand eines Überblicks über die Methode wird u.a. veranschaulicht, daß die Überführung von Zeitreihen in eine symbolische Repräsentation eine mehrstufige Vorgehensweise erfordert, so daß eine zunehmende Abstraktion von multivariaten Zeitreihen im Sinne einer "gleitenden" temporalen Wissenskonversion erfolgen kann. Im Anschluß daran werden die einzelnen Schritte der TWK beschrieben, wobei die Entdeckung von komplexen Mustern in Zeitreihen durch die TWK und deren Beschreibung durch eine temporale Grammatik gewonnen aus den Zwischenergebnissen der TWK getrennt betrachtet werden.

Der Einsatz von selbstorganisierenden Merkmalskarten (SOM) zur temporalen Wissenskonversion wird in *Kapitel 4* aufgezeigt. SOM eignen sich zur temporalen Wissenskonversion, da sie im Zusammenhang mit der U-Matrix-Methode zur Strukturanalyse eingesetzt werden können. Zur Erzeugung der Zwischenergebnisse auf den verschiedenen Ebenen der TWK sind hierarchische SOM erforderlich. Zeitliche Verläufe können anhand von Wegen auf U-Matrizen, die sich auf verschiedenen Ebenen befinden, beobachtet und interpretiert werden.

Die Anwendung der TWK auf ein nicht triviales Anwendungsbeispiel, auf schlafbezogene Atmungsstörungen (SBAS), wird in *Kapitel 5* beschrieben. Hierzu werden zunächst unterschiedliche Typen von SBAS beschrieben und ein Schema zur Klassifikation der Typen von Mustern von SBAS in der Medizin vorgestellt. Im Anschluß werden die verschiedenen Schritte der TWK von der Vorverarbeitung der Zeitreihen bis zur Gewinnung einer temporalen Grammatik dargestellt. Zuletzt wird eine Methode zur Evaluation der Ergebnisse durch eine Expertenbefragung vorgestellt. Die Ergebnisse der Expertenbefragung, die eine qualitative Bewertung der Ergebnisse der TWK angewandt auf SBAS liefern, werden hier vorgestellt.

In *Kapitel 6* wird die vorliegende Arbeit in vergleichbare Arbeiten eingeordnet. Zunächst wird unser Ansatz mit existierenden Ansätzen zur Verarbeitung von Zeit mit selbstorganisierenden Merkmalskarten (SOM) verglichen. Da ein wesentliches Ziel dieser Arbeit die Gewinnung einer geeigneten Wissensrepräsentation für komplexe Muster in multivariaten Zeitreihen gewesen ist, wird als nächstes unser Ansatz im Zusammenhang mit anderen Ansätzen aus der Künstlichen Intelligenz (KI) zur Repräsentation von Zeit sowie der syntaktischen Mustererkennung dargestellt. Letztendlich erfolgt eine Einordnung unseres Ansatzes in die verschiedenen Typen von hybriden Systemen.

In *Kapitel 7* werden eine Zusammenfassung der erzielten Ergebnisse und ein Ausblick auf weitere Arbeitsrichtungen gegeben.

Kapitel 2

Grundlagen

In diesem Kapitel werden Grundlagen für die im Rahmen dieser Arbeit entwickelte Methode eingeführt. Die vorgestellten Methoden stammen im wesentlichen aus dem Gebiet der künstlichen Intelligenz (KI) und der künstlichen neuronalen Netze (KNN) und zum Teil aus der Mustererkennung. Ziel der hier entwickelten Methode ist die Entdeckung von komplexen Mustern in Zeitreihen mit KNN und deren Überführung in eine symbolische Wissensrepräsentation.

Insbesondere eignen sich zur Entdeckung von Strukturen in Zeitreihen spezielle KNN, sog. selbstorganisierenden Merkmalskarten (SOM). In Kapitel 2.1 werden daher die Grundlagen von SOM eingeführt. Der Lernprozeß bei SOM findet unüberwacht statt, d. h. die Netzverbindungen (Gewichte) adaptieren sich durch Selbstorganisation an die strukturellen Eigenschaften von hochdimensionalen Daten. Durch SOM wird eine Abbildung eines hochdimensionalen Raumes auf eine in der Regel zweidimensionale Neuronenschicht (topographische Merkmalskarte) erzeugt derart, daß besondere Eigenschaften von Daten in einem hochdimensionalen Raum (Nachbarschaft und Dichte) auf einer Merkmalskarte so getreu wie möglich wiedergegeben werden. Erst durch eine geeignete Visualisierung der angelernten Netzstrukturen wie z.B. durch eine der U-Matrix-Methoden können Strukturen in hochdimensionalen Daten entdeckt werden. Die Entdeckung von Strukturen ist dabei wesentlicher Bestandteil einer Strukturanalyse. Eine Strukturanalyse beinhaltet außerdem eine automatische Erzeugung einer regelhaften Beschreibung der entdeckten Strukturen.

Durch die hier entwickelte Methode sollen zudem die in Zeitreihen (subsymbologische Wissensrepräsentation) entdeckten komplexen Muster in eine symbolische Wissensrepräsentation überführt werden. In Kapitel 2.2 werden daher Grundlagen

von hybriden Systemen eingeführt, bei denen verschiedene Wissensrepräsentationsformen durch die Integration von KNN und KI-Technologien realisiert werden. Dabei werden u. a. die Begriffe subsymbolische und symbolische Wissensrepräsentation geklärt. Hybride Systeme werden unterteilt in “kooperierende hybride Systeme“, die eine Art Kooperation zwischen verschiedenen Komponenten realisieren, und in “hybride Systeme mit Wissenskonversion“, bei denen ein Übergang zwischen subsymbolischer und symbolischer Wissensrepräsentation stattfindet. Ein solcher Übergang wird als Wissenskonversion bezeichnet. Die hier entwickelte Methode kann in die Klasse der “hybriden Systeme mit Wissenskonversion“ eingeordnet werden.

Betrachtet man die im Rahmen dieser Arbeit entwickelte Methode vom Standpunkt der Mustererkennung, so existieren gewisse Parallelen zwischen beiden Ansätzen. Bei beiden Ansätzen werden Muster auf verschiedenen Ebenen beschrieben. Durch die hier entwickelte Methode werden jedoch komplexe Muster in Zeitreihen durch eine Strukturanalyse explorativ entdeckt und beschrieben. Hingegen werden bei Mustererkennungssystemen komplexe Muster in der Regel als bekannt vorausgesetzt werden und in ihre einfacheren Bestandteile zerlegt, so daß eine Mustererkennung möglich wird. In der Mustererkennung spricht man dabei von einer “low-level“ und einer “high-level“ Mustererkennung. In Kapitel 2.3 werden daher grundlegende Begriffe der Mustererkennung eingeführt und verschiedene Methoden der Mustererkennung vorgestellt.

2.1 Selbstorganisierende Merkmalskarten (SOM)

Der Aufbau und die Lernfähigkeit von selbstorganisierenden Merkmalskarten (SOM) werden in Kapitel 2.1.1 vorgestellt. In Kapitel 2.1.2 werden die U-Matrix-Methoden vorgestellt, durch die die angelernten Netzstrukturen von SOM visualisiert werden. Werden Strukturen in hochdimensionalen Daten entdeckt, und für die entdeckten Klassen bedeutsame Namen in einer sprachlichen, regelhaften Form erzeugt, so wird dies als eine Strukturanalyse bezeichnet.

2.1.1 Grundlagen und Eigenschaften von SOM

Ziel der Neuroinformatik ist es, Funktionsprinzipien des biologischen Gehirns zu verstehen und die dabei gewonnenen Erkenntnisse für die Entwicklung neuartiger, flexiblerer Computer einzusetzen [Palm et al. 94]. Das biologische Gehirn scheint in vielen Bereichen in Form von zweidimensionalen Neuronenschichten organisiert zu sein [Sparks/Nelson 87]. Eingangssignale dieser Schichten sind entweder periphere Sinnesrezeptoren wie das auditorische System oder andere neuronale Schichten. Innerhalb dieser Schichten lassen sich benachbarte Neuronengruppen finden, die zu höheren funktionellen Einheiten zusammengeschlossen werden. Diese werden dann auf nächsthöheren Organisationsebenen zu Feldern ausgebildet, die spezialisierte Teilaufgaben des Gehirns repräsentieren und ausführen. Zu diesen Teilaufgaben gehören beispielsweise die visuelle Wahrnehmung, die Bewegungskontrolle sowie die Tastwahrnehmung. Obwohl die verschiedenen Teilaufgaben sich voneinander unterscheiden, weisen sie dennoch auf struktureller Ebene eine ausgeprägte Homogenität auf. Verbindungen zwischen den Schichten in der Hirnrinde (Kortex) unterliegen im wesentlichen einem „topographischen“ Organisationsprinzip, nach dem benachbarte Neuronen aus dem Ausgangsfeld mit benachbarten Neuronen aus dem Zielfeld verbunden sind.

Insbesondere nähern sich die von Kohonen (1984) vorgeschlagenen selbstorganisierenden Merkmalskarten¹ (SOM) dem „topographische“ Organisationsprinzip der Hirnrinde an. Durch SOM wird eine Abbildung vom \mathbb{R}^n auf einen Raum mit niedrigerer Dimension \mathbb{R}^m mit $m \leq n$ erzeugt. Durch diese Abbildung wird ver-

1. Engl. selforganizing feature map

sucht, bestimmte Eigenschaften (Nachbarschaften und Dichte) von Daten im \mathbb{R}^n auf einer niedriger dimensionalen Neuronenschicht im \mathbb{R}^m soweit wie möglich zu erhalten [Ritter et al. 92]. Häufig wird $m=2$ gewählt. Dabei werden Eingabedaten aus dem \mathbb{R}^n auf eine zweidimensionale Neuronenschicht abgebildet.

Im folgenden werden einige grundlegende Begriffe für KNN eingeführt, so daß darauf aufbauend grundlegende Eigenschaften von SOM dargestellt werden können. KNN sind Computerprogramme, die Prinzipien realisieren, die aus der Beobachtung biologischer neuronaler Netze entlehnt worden sind [Ultsch 96a]. Ein KNN wird häufig als Graph $G=(U, W)$ dargestellt, der aus einer Menge U von Verarbeitungseinheiten (*Neuronen*) und einer Menge W von gewichteten Kanten (*Gewichte*) zwischen den Neuronen besteht. Durch Veränderungen der Gewichte erfolgt eine Anpassung der Gewichte an die *Lerndaten*. Dieser Prozeß wird als *Lernen* bezeichnet. Durch einen *Lernschritt* werden die Gewichte zu einem bestimmten Zeitpunkt für einen beliebigen Eingabevektor verändert.

Es wird zwischen überwachten und unüberwachten Lernverfahren unterschieden. Bei *überwachten Lernverfahren* ist die zu einer Eingabe gehörende Ausgabe immer bekannt. Stimmt die durch ein KNN berechnete Ausgabe für eine bestimmte Eingabe mit den Lerndaten nicht überein, so werden die Gewichte korrigiert [Rojas 93]. Die Fehlerkorrektur erfolgt dabei durch einen Lernalgorithmus. Bei *unüberwachten Lernverfahren* ist nur die Eingabe bekannt. Hier werden die strukturellen Eigenschaften der Lerndaten benutzt (Regelmäßigkeiten, Häufigkeiten, Ähnlichkeiten), um Änderungen der Gewichte vorzunehmen [Ultsch 91].

SOM sind spezielle KNN mit unüberwachtem Lernverfahren, bei denen jedes Neuron der Eingabeschicht über *Gewichte* mit Neuronen einer Neuronenschicht verbunden ist. Besteht diese Neuronenschicht aus einer zweidimensionalen Neuronenschicht, so wird diese als (*topographische*) *Merkmalskarte* bezeichnet [Ritter et al. 92] (s. Abb.1). Die räumliche Anordnung der Neuronen auf der Merkmalskarte ist bei SOM von entscheidender Bedeutung. Insbesondere spielt für das Lernverfahren die Nachbarschaft zwischen den Neuronen auf der Merkmalskarte eine besondere Rolle, d.h. welche Neuronen benachbart sind und in einen Lernschritt miteinbezogen werden. Dabei wird das Lernen häufig als Lernen mit "lateraler Inhibition" aufgefaßt [Ultsch 88, Ritter et al. 92]. Die *Eingabeschicht* dient dazu, einen mehrdimensionalen Eingabevektor aufzunehmen.

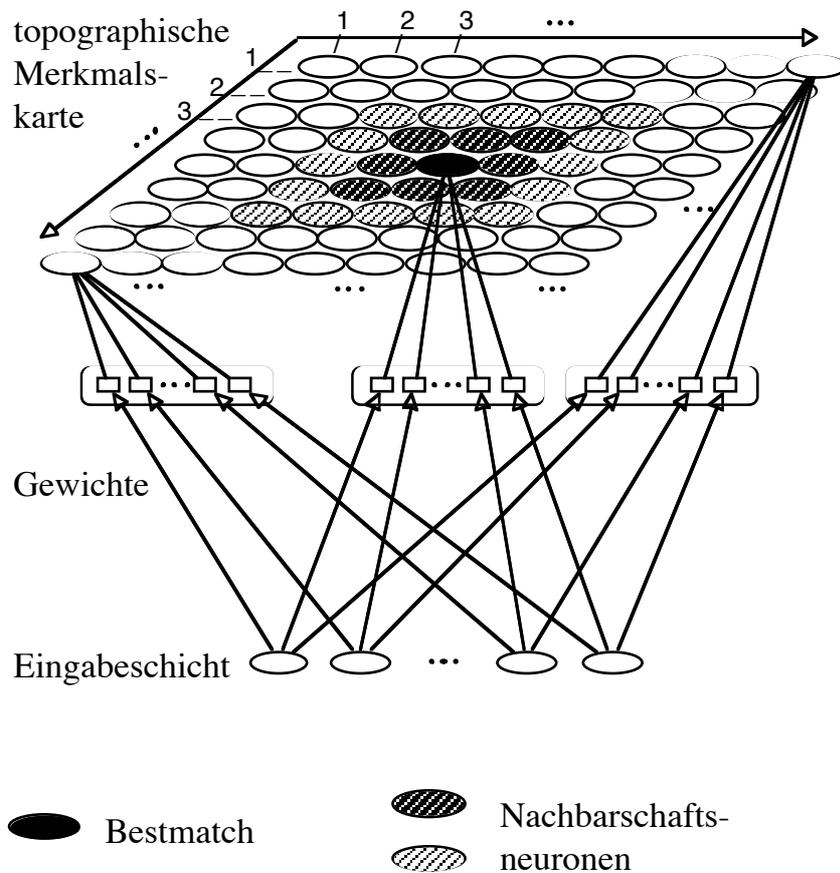


Abb.1: Selbstorganisierende Merkmalskarte (SOM)

Der Lernprozeß von SOM läßt sich durch folgenden Algorithmus beschreiben [Kohonen 82, Kohonen 84]:

Vor dem Lernen werden die Gewichte mit geeigneten Anfangswerten initialisiert [Ritter et al. 92]. Das Lernen erfolgt dann durch eine wiederholte Ausführung folgender Schritte. Als erstes wird ein Eingabevektor aus der Menge der Lerndaten ausgewählt. In einem weiteren Schritt erzeugt der Eingabevektor Aktivierungen auf der Merkmalskarte derart, daß nur ein Neuron auf der Merkmalskarte aktiviert wird. Dieses Neuron ist dem Eingabevektor $v = (v_1, \dots, v_n)$ gemäß einer gegebenen Metrik am ähnlichsten und wird als *Bestmatch* (s. Abb.1) bezeichnet. Der Bestmatch r' wird durch

$$\|w_{r'} - v\| = \min_r \|w_r - v\| \quad (2.2.1)$$

mit $w_r = (w_{r1}, \dots, w_{rn})$ bestimmt. Dabei steht $\|x\|$ für eine beliebige Vektor-

norm. Häufig wird der euklidische Abstand $\sqrt{\sum_{j=1}^n (w_{rj} - v_j)^2}$ zur Bestimmung des Bestmatches verwendet. Ggf. können sich jedoch andere Abstandmaße als geeigneter erweisen [Kohonen 95].

Nach der Bestimmung des Bestmatches r' für einen Eingabevektor v findet der eigentliche Lernprozeß (Anpassung der Gewichte) statt. Der Lernprozeß läßt sich durch eine Funktion $h_{rr'}(t)$ beschreiben, die die Gewichte w_r in einer Nachbarschaft um den Bestmatch r' um

$$\Delta w_r = \eta(t) \cdot h_{rr'}(t) \cdot (v - w_r) \quad (2.2.2)$$

verändert [Kohonen 84]. Die Größe $\eta(t)$ wird als Lernrate bezeichnet und bestimmt die Größe des Adaptionsschrittes mit $0 < \eta(t) < 1$. Für die Veränderung der Gewichte Δw_r wird vorausgesetzt, daß $h_{rr'}(t) > 0$ und die Funktion $h_{rr'}(t)$ ein Maximum an der Stelle r' besitzt. Eine häufig verwendete Funktion ist die gaußsche Glockenkurve

$$h_{rr'}(t) = e^{-\frac{(r-r')^2}{2\sigma(t)^2}}, \quad (2.2.3)$$

wobei durch den Lernradius $\sigma(t)$ die Neuronen in einer Nachbarschaft um den Bestmatch r' festgelegt werden. Für die Erzeugung einer Merkmalskarte ist die Auswahl der gaußschen Glockenkurve aus (2.2.3) nicht zwingend. Durch den Einsatz anderer Funktionen (s. Abb.2) werden gleich gute Ergebnisse erzielt, die bzgl. der Rechenzeit sogar effizienter sind [Zell 94, Kohonen 94]. Während des Lernens werden die Lernrate $\eta(t)$ und der Lernradius $\sigma(t)$ verringert. Für eine geeignete Wahl dieser Parameter siehe Ritter et al. (1992).

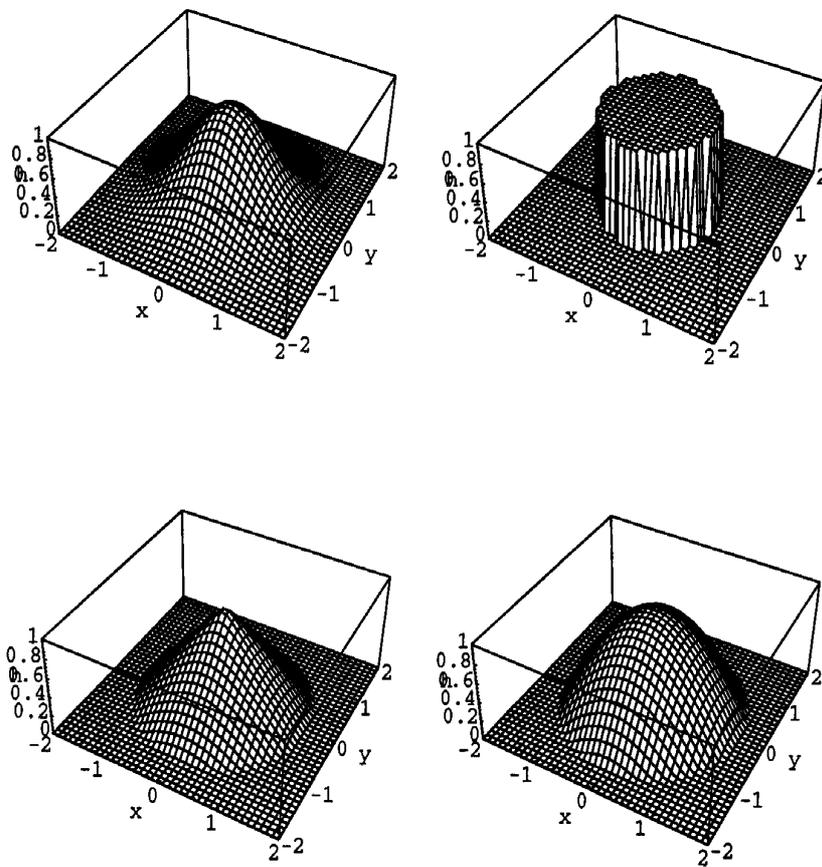


Abb.2: Verschiedene Distanzfunktionen für eine Merkmalskarte: a)gaußsche Glockenkurve, b) Zylinder, c) Konus, d) Kosinus (in [Zell 94]).

SOM wurden bisher in sehr vielen Bereichen eingesetzt [Kohonen 95]. Im wesentlichen beruhen diese Anwendungen auf der besonderen Eigenschaft von SOM, sich in geeigneter Weise an die Strukturen mehrdimensionaler Eingabevektoren anzupassen. Die eigentliche Erkennung von Strukturen in mehrdimensionalen Daten ist aber erst durch eine Visualisierung der angelegten Netzstrukturen von SOM möglich.

2.1.2 U-Matrizen zur Strukturanalyse

In dieser Arbeit sollen SOM zu Entdeckung von Strukturen in hochdimensionalen Daten eingesetzt werden. Hierzu ist eine geeignete Visualisierung der angelernten Netzstrukturen von SOM durch U-Matrizen (s. u.) erforderlich. Wird zudem für die entdeckten Klassen automatisch eine regelhafte Beschreibung erzeugt, so daß eine für die Anwendung bedeutsame Beschreibung der Klassen hergeleitet werden kann, so wird dies als eine Strukturanalyse¹ bezeichnet.

Strukturanalyse

Ziel einer Strukturanalyse ist die Erzeugung einer computergraphischen Darstellung von hochdimensionalen Daten derart, daß disjunkte Klassen in hochdimensionalen Daten entdeckt werden können, sowie die Erzeugung einer Beschreibung der Klassen in einer regelhaften Form, so daß jeder Klasse ein für die Anwendung bedeutsamer Name zugeordnet werden kann.

Damit unterscheidet sich die Strukturanalyse von einer Clusteranalyse. Beispielsweise liefert die graphische Darstellung eines Ergebnisses einer hierarchischen Clusteranalyse durch ein Dendrogramm den *ersten Teil einer Strukturanalyse*, falls hierdurch Klassen erkannt werden können. Hier fehlt jedoch als *zweiter Teil einer Strukturanalyse* die Gewinnung einer sprachlichen Beschreibung für die entdeckten Klassen. Ein Werkzeug für eine erfolgreiche Strukturanalyse ist die Kombination der U-Matrix-Methoden [Ultsch 92] mit dem Regelgenerierungsalgorithmus sig* [Ultsch 93a].

Durch U-Matrizen kann der erste Teil einer Strukturanalyse durchgeführt werden, d. h. Strukturen in hochdimensionalen Daten entdeckt werden. Dabei wird durch eine der U-Matrix-Methoden (s.u.) eine geeignete Visualisierung der angelernten Netzstrukturen von SOM derart erzeugt, daß eine dreidimensionale Landschaft entsteht (s. Abb.4). Eine solche Landschaft kann folgendermaßen interpretiert werden: Die in einem "Tal" sich befindenden Bestmatches, die einem Datenpunkt im \mathbb{R}^n entsprechen, liegen im \mathbb{R}^n nahe beieinander und können ggf. zu einer Klasse zusammengefaßt werden. "Mauern" auf einer U-Matrix trennen Bereiche im \mathbb{R}^n , die einen großen Abstand voneinander besitzen. Die unterschiedliche Höhe der "Mauern" zwischen den "Tälern" liefert einen Hinweis auf die Heterogenität zwischen den Klassen. Alle Bereiche auf einer U-Matrix, die keiner bestimmten Klasse zugeordnet werden, können einer besonderen Klasse zugeordnet

1. pers. Kommunikation mit A. Ultsch (1997)

werden. Durch eine U-Matrix kann eine vollständige Zerlegung einer Menge von hochdimensionalen Daten in Klassen erreicht werden. Wird eine Strukturanalyse anhand einer U-Matrix durchgeführt, so wird jeder Datenpunkt des \mathbb{R}^n genau einer Klasse zugeordnet. Das heißt, daß eine Überdeckung von Klassen hier nicht möglich ist. Die Anzahl der "Täler" liefert dabei einen Hinweis für die Anzahl der Klassen. Mehrere "Täler" können u.U. zu einer Klasse zusammengefaßt werden.

Die einfachste U-Matrix-Methode ist die Distanz-Methode. Dabei werden die Abstände zwischen benachbarten Gewichten auf einer Merkmalskarte in der dritten Dimension abgebildet (s. Abb.3). Bei der Two-Match-Methode werden die Abstände zwischen benachbarten Bestmatches gewichtet und in der dritten Dimension abgebildet.

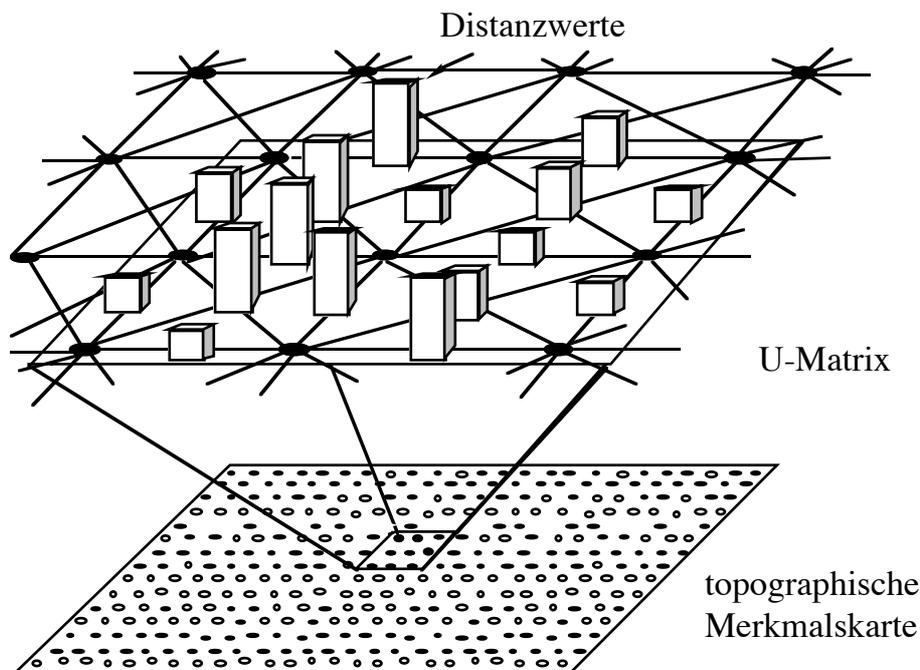


Abb.3: Einfachste U-Matrix-Methode, die Distanz-Methode (in [Ultsch 92]).

In Abb.4 ist eine U-Matrix eines künstlich erzeugten Datensatzes dargestellt. Hier wurden um die 6 Eckpunkte eines Oktaeders räumlich verteilte Datenpunkte erzeugt. Die Aufteilung der Daten in die 6 Klassen des Datensatzes ist bei diesem Beispiel deutlich zu sehen. Dabei deuten die dunklen Bereiche auf der U-Matrix auf Klassen und die farbigen "Mauern" auf große Abstände zwischen den Klassen hin. Durch Farbkodierung können auch unterschiedlich hohe "Mauern" erkennbar

gemacht werden.

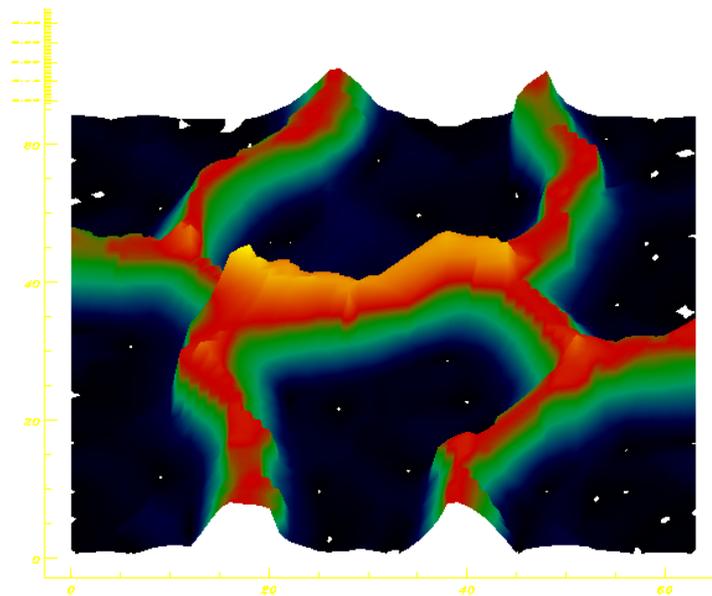


Abb.4: U-Matrix der Oktaeder-Daten

Liegt der Bestmatch eines neuen Datensatzes in einem “Tal“, so ist die Klassenzugehörigkeit eindeutig. Bei der Klassifikation eines neuen Datensatzes treten dann Schwierigkeiten bei der Interpretation einer U-Matrix auf, wenn der Bestmatch auf eine der “Mauern“ fällt. Dies kann unterschiedlich interpretiert werden. Zum einen kann es sich um einen Fall handeln, der zwischen den beiden durch eine “Mauer“ getrennten Klassen liegt. Zum anderen kann es sich um einen “neuartigen“ Fall handeln. Durch Angabe eines Schwellwertes für den Abstand zwischen Bestmatch und Eingabevektor im \mathbb{R}^n kann u.U. entschieden werden, ob es sich um einen “neuartigen“ Fall handelt oder nicht [Alander et al. 91].

U-Matrizen wurden bereits in verschiedenen Anwendungsbereichen eingesetzt. Erste Anwendungen lagen im medizinischen Bereich [Ultsch 91]. Dabei wurden Daten über Störungen des Säure-Basen-Haushaltes (Azidose) sowie Daten über eventuell vorhandenem Eisenmangel untersucht. Weitere Anwendungen in der Medizin lagen im Bereich der Liquoranalyse [Kleine et al. 96, Ultsch et al. 97]. Außerdem wurden Einsatzmöglichkeiten von SOM zur Strukturanalyse im Umweltbereich untersucht [Ultsch 94a]. In der Meteorologie wurden durch U-Matrizen verschiedene Lawinen-Gefahrenstufen in der Schweiz klassifiziert [Schweizer et al. 94]. Weitere Anwendungsbereiche sind u.a. die Klassifikation meeresbiologischer Sedimentationen [Ultsch et al. 95b], die Erkennung verschied-

dener chemischer Prozeßzustände [Ultsch 93], die Untersuchung des Wohlstands verschiedener Länder [Kaski/Kohonen 96] und die Analyse von Strukturen japanischer Phoneme [Kohonen 95].

2.2 Hybride Systeme

Zur Begriffsklärung von symbolischer und subsymbolischer Wissensrepräsentation werden im folgenden die den zugrundeliegenden Begriffe Symbol und Wissen eingeführt.

Symbol

Ein *Symbol* ist laut Fremdwörterlexikon ein “Gegenstand oder Vorgang, der stellvertretend für einen anderen nicht wahrnehmenden Sachverhalt steht“ [Duden 90].

In einem Lexikon der Informatik ist Symbol definiert als “ein Zeichen oder eine Zeichenfolge, die zur Darstellung eines Begriffsinhaltes oder eines Sachverhaltes verwendet wird“ [Schneider 91, S. 786].

Dies bedeutet, daß in der Informatik “Gegenstand oder Sachverhalt“ als “Zeichen oder Zeichenfolge“ eines Alphabets interpretiert wird. Dabei wird “Zeichen oder Zeichenfolge“ als ein atomares, nicht zerlegbares Gebilde verstanden, das zur Darstellung eines Begriffsinhaltes oder eines (nicht wahrgenommenen) Sachverhaltes verwendet wird. Der Begriffsinhalt wird auch als die Bedeutung (Semantik) von “Zeichen oder Zeichenfolge“ angesehen [Ultsch 96].

Wissensrepräsentation ist einer von der Informatik bzw. von der künstlichen Intelligenz (KI) geprägter Begriff. Hier wird eine geeignete Repräsentation bzw. Darstellung von Wissen für eine gegebene Problemstellung gesucht, so daß Wissen durch einen “Interpreter mit Symbolverarbeitungskompetenz“ [Ultsch 87] bzw. durch eine “semantische Maschine“ [Bibel et al. 93] verarbeitet werden kann. Ein solche Maschine enthält Operationen zum Wissensmanagement (Hinzufügen, Entfernen und Auffinden von Wissen) und zum Ziehen von Schlußfolgerungen aus vorhandenem Wissen (Inferenz). Soll Wissen in eine Maschine eingebaut werden, so stellt sich die Frage, was Wissen ist und wie es sich materialisieren und einbauen läßt. Der Begriff Wissen ist weitaus schwieriger zu prä-

zisieren als der Begriff Symbol. Selbst in der Kognitionswissenschaft wird der Begriff Wissen nicht einheitlich verwendet [Strube et al. 93]. In einem Lexikon der Informatik wird der Begriff Wissen folgendermaßen beschrieben:

Wissen

“*Wissen* bezieht sich stets auf Handlungsbereiche, in denen es als Verfügungswissen ein Handlungsvermögen konkretisiert oder als Orientierungswissen Einstellungen und Haltungen prägt“. “Jedes *Wissen* ist zunächst als subjektives Wissen eine geheimnisvolle Mischung aus Intuition, Erfahrung, Informiertheit, Bildung und Urteilskraft. Es kann im Zuge eines kommunikativen Handelns (teilweise) sprachlich rekonstruiert, in Diskursen nach transsubjektiv gültigen Kriterien ausgearbeitet und im Idealfall in ein objektives Wissen überführt werden.“ [Schneider 91, S. 896]

Bei gegebener Problemstellung und verfügbarer Wissensquelle ist es das Ziel einer zukünftigen Theorie der Wissensrepräsentation, daß “sie einen dazu passenden Formalismus (bzw. Formalismen) bereitstellt, der die Akquisition des erforderlichen Wissens aus der genannten Quelle in einer Form ermöglicht, die dieses Wissen für den Menschen und für die Maschine verständlich repräsentiert und zur möglichst effizienten Problemlösung beiträgt“ [Bibel et al. 93, S. 13]. Dabei kann Wissen in symbolischer bzw. in subsymbolischer Form repräsentiert werden [Rumelhart/ McClelland 86].

Eine subsymbolische Wissensrepräsentation unterscheidet sich von einer symbolischen Wissensrepräsentation dadurch, daß ein Symbol durch eine Vielzahl von Einheiten repräsentiert wird, die für sich alleine keine Bedeutung besitzen. Erst durch ein kollektives Zusammenwirken der beteiligten Einheiten entsteht ein Symbol.

Subsymbolische Wissensrepräsentation

Nach Ultsch (1996) wird als *subsymbolische Wissensrepräsentation* die Aufteilung eines zu repräsentierenden Sachverhaltes bzw. Symbols auf eine Vielzahl von Einheiten (Units, Neuronen, Gewichtskomponenten) verstanden, so daß

- “das repräsentierte Symbol erst durch ein kollektives Zusammenwirken (Synergie) der beteiligten Einheiten entsteht,
- keine Einheit für sich alleine bedeutungstragend (im Kontext des zu repräsentierenden Symbols bzw. Sachverhalts) ist,

- keine Einheit für sich alleine genommen eine Identifizierung des Repräsentierten erlaubt,
- ein Ausfall von einzelnen Einheiten nicht die Identität des von allen gemeinsam repräsentierten Symbols wesentlich ändert (Redundanz/ Fehlertoleranz).“

Symbolische Wissensrepräsentation

Eine *symbolische Wissensrepräsentation* erfolgt stets in einer für Menschen verständlichen, sprachlichen Form, wobei das Wissen mit Hilfe von Zeichen, die in einem jeweiligen Kontext als atomar gedacht sind, repräsentiert ist [Ultsch 96].

Beispiel aus [Ultsch 96]

Folgende Zahlen sind eine subsymbolische Repräsentation eines Teils des Inhalts einer CD mit Bizet's Oper Carmen.

128 128 128 128 128 130 127 128 134 125 121 136 133 112 126 139 121 132 137 122 131 136 115
 140 140 106 118 139 114 124 153 111 111 159 134 103 142 139 97 124 148 108 111 153 118 106
 150 139 106 193 193 14 64 188 96 164 138 74 171 175 27 160 148 75 128 199 96 108 142 132 132
 103 138 145 108 103 159 122 114 132 134 114 124 118 138 117 134 134 103 96 164 100 117 148
 128 128 132 122 108 177 132 117 70 175 139 31 134 156 100 156 124 128 139 81 106 159 114 117
 170 124 103 132 118 100 132 134 114 148 118 134 124 118 128 138 111 128 134 114 138 132 111
 100 139 122 117 134 148 153 111 111 159 134 103 142 139 97 124 148 108 111 153 118 106 150
 139 106 134 142 103 124 145 114 114 148 128 111 142 138 108 134 150 108 103 148 132 111 142
 124 114 145 134 114 138 128 111 124132 134 114 124 118 138 117 134 134 103 96 164 100 117
 148 128 128 132 122 64 128 118 128 134 192 111 124 128 118 90 118 188 148 86 145 170 92 79
 148 171 142 118 128 159 122 68 114 166 159118 134 124 118 128 138 111...

Eine einzelne Zahl für sich alleine genommen besitzt im Kontext des Musikhörens keine Bedeutung. Eine Zahl kann dabei verändert oder entfernt werden, ohne das Musikstück wesentlich zu ändern.

Eine symbolische Repräsentation desselben Inhalts ist die Partitur dieses Musikstücks, wobei die Noten als Symbole aufgefaßt werden (s. Abb.5).



Abb.5: Noten aus Georges Bizet's Oper Carmen

Die Vorteile einer symbolischen Wissenrepräsentation in KI-Technologien liegen z.B. in der Interpretierbarkeit, in der relativ leichten expliziten Kontrolle und in der Wissensabstraktion [Wermter 95]. Vorteile einer subsymbolischen Wissensrepräsentation in KNN liegen in der Lernfähigkeit, in der robusten Verarbeitung von Daten und in der Generalisierungsfähigkeit auf ähnliche oder sogar fehlerhafte Daten [Gallant 93, Palm et al. 94].

In hybriden Systemen werden unterschiedliche Technologien, die verschiedene Formen der Wissensrepräsentation realisieren, in ein Gesamtsystem integriert. Häufig in hybriden Systemen eingesetzte Technologien sind KNN und Technologien der symbolischen KI, aber auch evolutionäre Algorithmen, Fuzzy-Technologien, u.s.w. Durch eine Hybridisierung sollen die Einschränkungen verschiedener Technologien aufgehoben werden, da bei der Lösung komplexer Probleme unterschiedliche Anforderungen an die verschiedenen Techniken gestellt werden. Die in einem hybriden System integrierten Technologien, die üblicherweise ergänzende Eigenschaften besitzen, werden dabei zur Lösung unterschiedlicher Teilprobleme eingesetzt [Goonatilake/Khebal 95].

Unter dem Begriff "hybrid" wird eine "Zwitterbildung", "Mischbildung" bzw. "Zusammensetzung aus Verschiedenem" verstanden [Duden 90]. Im Zusammenhang mit hybriden Systemen kann der Begriff "hybrid" unterschiedlich interpretiert werden. Unter den Begriffen "Mischbildung" bzw. "Zusammensetzung aus Verschiedenem" kann irgendeine Art von Kooperation zwischen unterschiedlichen Komponenten eines Systems verstanden werden. Der Begriff "Zwitterbildung" liefert einen Hinweis auf eine starke Vernetzung der unterschiedlichen Komponenten, so daß ein Übergang zwischen verschiedenen Repräsentationsformen in einem System denkbar ist.

In Ultsch (1996) wird zwischen zwei grundsätzlich unterschiedlichen Formen der Integration von KNN und KI-Technologien in hybriden Systemen unterschieden, den "kooperierenden hybriden Systemen" und den "hybriden Systemen mit Wissenskonversion". Sehr häufig wird in hybriden Systemen eine Art Kooperation bzw. Interaktion zwischen einzelnen Komponenten eines hybriden Systems realisiert [Goonatilake/Khebal 95]. Verschiedene Möglichkeiten zur Kopplung von KI-Technologien und KNN liegen u.a. im Bereich des probabilistischen Schließens, der Unifikation, der Verbesserung des Reasoning und der Optimierung der Inferenzstrategie [Ultsch 91].

Kooperierende hybride Systeme

Bei *kooperierenden hybriden Systemen* findet kein Übergang zwischen subsymbolischer und symbolischer Wissensrepräsentation statt. Unabhängige, in sich geschlossene Module kooperieren miteinander, wobei die einzelnen Module durch verschiedene Technologien realisiert werden.

Bei “kooperierenden hybriden Systemen“ findet kein Übergang zwischen verschiedenen Wissensrepräsentationsformen statt. Findet ein Übergang zwischen verschiedenen Wissensrepräsentationen statt, so wird das als Wissenskonversion bezeichnet [Ultsch 96]. Unter Wissenskonversion werden z. B. die Realisierung eines Inferenzmechanismus in KNN [Ultsch et al. 94] oder umgekehrt die Überführung angelernter Netzstrukturen in einem KNN in eine symbolische Form [Ultsch 93a] verstanden.

Wissenskonversion [Ultsch 96]

Als *Wissenskonversion* wird der Übergang zwischen subsymbolischer und symbolischer Wissensrepräsentation bezeichnet.

Bei den “eigentlichen“ hybriden Systemen findet ein Übergang zwischen den verschiedenen Wissensrepräsentationsformen (symbolische vs. subsymbolische) in Form einer Wissenskonversion statt. Solche hybride Systeme werden im Rahmen dieser Arbeit als “hybride Systeme mit Wissenskonversion“ bezeichnet.

Hybride Systeme mit Wissenskonversion

Hybride Systeme mit Wissenskonversion sind dadurch gekennzeichnet, daß ein Übergang zwischen unterschiedlichen Wissensrepräsentationsformen (subsymbolisch vs. symbolisch) stattfindet.

In Ultsch (1991) wird vorgeschlagen, selbstorganisierende Merkmalskarten (SOM) nach dem Modell von Kohonen (1984) zur Wissensakquisition für Expertensysteme einzusetzen. Die Wissenskonversion findet hier statt als Übergang einer in den angelernten Netzstrukturen der SOM vorhandenen subsymbolischen Wissensrepräsentation in eine symbolische Wissensrepräsentation [Ultsch 94].

Im Rahmen dieser Arbeit werden ausschließlich zeitliche Phänomene betrachtet. Dabei werden Zeitreihen als eine temporale, subsymbolische Wissensrepräsentation betrachtet. Werden Zeitreihen bzw. komplexe Muster in Zeitreihen mit KNN in eine für Menschen verständliche, sprachliche Beschreibung überführt, so wird

dies als temporale Wissenskonversion bezeichnet. Der Übergang kann dabei schrittweise erfolgen.

Temporale Wissenskonversion

Ein ggf. sukzessiver bzw. schrittweiser Übergang von komplexen Mustern in Zeitreihen in eine temporale, symbolische Wissensrepräsentation wird als *temporale Wissenskonversion* bezeichnet.

Die im Rahmen dieser Arbeit entwickelte Methode zur temporalen Wissenskonversion kann in die Klasse der “hybriden Systeme mit Wissenskonversion“ eingeordnet werden. Dabei entsprechen Zeitreihen einer temporalen, subsymbolischen Wissensrepräsentation und die für Menschen verständliche, sprachliche Beschreibung von Mustern in Zeitreihen einer temporalen, symbolischen Wissensrepräsentation.

2.3 Mustererkennung und Mustererkennungssysteme

In Kapitel 2.3.1 werden grundlegende Begriffe der Mustererkennung eingeführt. Kapitel 2.3.2 liefert einen Überblick über “low-level“ Mustererkennungssystemen. In Kapitel 2.3.3 werden Grundbausteinen von “high-level“ Mustererkennungssystemen, bei denen insbesondere Methoden der syntaktische Analyse eingesetzt werden.

2.3.1 Grundlegende Begriffe der Mustererkennung

Das wesentliche Ziel der Mustererkennung ist die Identifizierung, Klassifikation und Beschreibung von Mustern in Daten [Kanal/Dattatreya 92, Schalkoff 92]. Dabei wird zwischen primitiven und komplexen Mustern unterschieden. Primitive Muster bilden die Grundbausteine von komplexen Mustern.

Primitive Muster

Primitive Muster werden durch Merkmale beschrieben, die eine Zuordnung des primitiven Musters als Ganzes in eine Klasse erlauben [Niemann 90].

Da komplexe Muster bestimmte strukturelle Eigenschaften besitzen, führt nicht irgendeine strukturelle und/oder hierarchische Anordnung der primitiven Muster zu einer Beschreibung eines komplexen Musters. Hingegen bestehen viele Muster aus relativ wenigen strukturellen und/oder hierarchischen Anordnungen von primitiven Mustern.

Komplexe Muster

Komplexe Muster bestehen aus mehreren primitiven Mustern, die bestimmte strukturelle und/oder hierarchische Beziehungen untereinander aufweisen [Niemann 90].

Durch zusätzlichen Einsatz von KI-Technologien neben den klassischen Methoden der Mustererkennung wird eine Analyse, Beschreibung und Interpretation von komplexen Mustern angestrebt [Niemann 90].

Mustererkennung

Der Prozeß der *Mustererkennung* beinhaltet die Klassifikation von primitiven Mustern sowie eine Analyse, Beschreibung und Interpretation von komplexen Mustern.

Die Zerlegung eines sehr schwierigen Problems in Teilprobleme erfordert häufig den Einsatz verschiedener Technologien. In der Mustererkennung wird von "low-level" und "high-level" Mustererkennung gesprochen, falls diese auf verschiedenen Ebenen stattfindet [Goonatilake/Khebal 95, Niemann 90, Kanal/Dattatreya 92].

low-level / high-level Mustererkennung

Eine *low-level Mustererkennung* beinhaltet die Vorverarbeitung und Segmentierung von komplexen Mustern auf einer datennahen Ebene.

Eine *high-level Mustererkennung* beinhaltet die Identifizierung und Beschreibung struktureller und/oder hierarchischer Beziehungen zwischen primitiven Mustern.

Zur low-level Mustererkennung werden u.a. Methoden aus der Statistik [Fukunaga 90] und KNN [Bishop 95, Masters 93] eingesetzt. Zur high-level Mustererkennung werden u.a. Methoden der Syntaxanalyse eingesetzt, wobei komplexe Muster grammatikalisch beschrieben werden [Tou/Gonzalez 74, Kanal/Dattatreya 92, Schalkoff 92]. In Mustererkennungssystemen sollte sowohl eine low-level Mustererkennung als auch eine high-level Mustererkennung stattfinden [Niemann 90].

2.3.2 Aufbau von "low-level" Mustererkennungssystemen

Die Mustererkennung in der Statistik ist ein seit vielen Jahren etabliertes Gebiet. Schon seit Anfang der 70iger Jahre existiert umfangreiche Literatur zu Mustererkennungssystemen, bei denen statistische Methoden eingesetzt werden [Duda/Hart 73, Tou/Gonzalez 74, Devijver/Kittler 82].

Ziel der statistischen Mustererkennung ist es, Mechanismen in Entscheidungsprozessen bei der Mustererkennung durch den Einsatz von statistischen Methoden zu automatisieren. Dabei geht es in der statistischen Mustererkennung u.a. um die

Schätzung von Dichtefunktionen und die Zerlegung eines hochdimensionalen Datenraumes in Klassen [Fukunaga 90]. Das Anwendungsfeld der statistischen Mustererkennung erstreckt sich über ein weites Gebiet, von der Identifizierung von räumlichen Mustern, z.B. bei der Schrifterkennung, bis hin zur Identifizierung von zeitlichen Mustern, z.B. bei der Spracherkennung.

Im allgemeinen werden bei der Entwicklung von Mustererkennungssystemen in der Statistik folgende Schritte durchlaufen (s. Abb.6):

1. *Pattern Analysis*: Dies ist ein wichtiger anwendungsabhängiger Schritt im Systementwicklungsprozeß [Fukunaga 90]. Dabei wird häufig eine Normierung von Daten durchgeführt.
2. *Feature Extraction*: In diesem Schritt erfolgt die Auswahl geeigneter Merkmale (engl. features) aus den Daten. Wesentliches Ziel ist es hier, den Merkmalsraum so stark wie möglich einzugrenzen, ohne die Trennbarkeit der Klassen untereinander deutlich zu reduzieren. Dies ist ein Schritt, der die Güte eines Klassifikators stark beeinflusst [Kanal/Dattatreya 92].
3. *Classification*: In diesem Schritt wird eine Klassifikation der Merkmale durchgeführt. Die Auswahl eines Klassifikators hängt im wesentlichen von der zur Verfügung stehenden a priori Information ab, wobei parametrische, nicht-parametrische Verfahren oder Clusterverfahren eingesetzt werden können [Kanal/Dattatreya 92].
4. Zuletzt wird die Güte des Klassifikators überprüft. Sowohl die Auswahl geeigneter Merkmale als auch die Auswahl und Konstruktion eines Klassifikators sind entscheidende Faktoren für der Güte eines Klassifikators [Fukunaga 90].

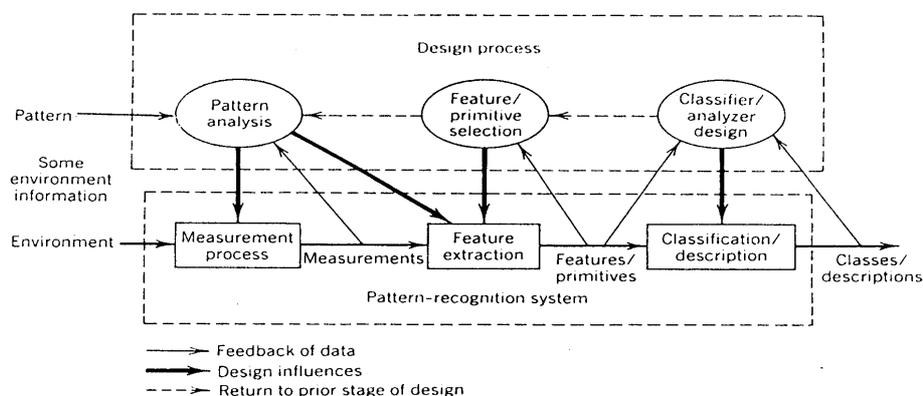


Abb.6: Schritte bei der Entwicklung eines Mustererkennungssystems in der Statistik (in [Kanal/Dattatreya 92]).

Durch statistische Methoden zur Mustererkennung wird eher eine "low-level" Mustererkennung durchgeführt. Zur Identifizierung von primitiven Mustern werden hauptsächlich die statistischen Eigenschaften mehrdimensionaler Daten untersucht.

In den letzten Jahren wurden vermehrt KNN zur "low-level" Mustererkennung eingesetzt [Pao 89, Schalkoff 92, Kanal/Dattatreya 92, Bishop 95]. Es handelt sich dabei hauptsächlich um KNN mit überwachtem Lernverfahren, wie den Backpropagation Lernalgorithmus.

2.3.3 Grundbausteine eines syntaktischen Mustererkennungssystems

Der Bereich der syntaktischen Mustererkennung wird seit Anfang der 70iger Jahre erforscht [Fu 74, Tou/Gonzalez 74, Gonzalez/Thomason 78]. Diese Verfahren werden jedoch wesentlich weniger häufig als die o.g. Verfahren zur Mustererkennung eingesetzt. Die syntaktische Mustererkennung kann als eine Ergänzung zu den konventionellen Methoden der Mustererkennung aufgefaßt werden. Statistische Methoden und neuerdings auch KNN eignen sich eher zur Identifizierung von primitiven Mustern, jedoch nicht zur Beschreibung der strukturellen Abhängigkeiten zwischen primitiven Mustern [Kanal/Dattatreya 92]. Primitive Muster bilden somit die Grundbausteine, sog. "building blocks", zur Beschreibung komplexer Muster.

Ziel der syntaktischen Mustererkennung ist es, aus den strukturellen Informationen, die zwischen verschiedenen primitiven Mustern existieren, Beschreibungen für komplexe Muster zu generieren. Da diese strukturellen Abhängigkeiten zwischen primitiven Mustern in realen Anwendungen komplex und vielfältig sein können, müssen hier Methoden eingesetzt werden, die ähnliche Strukturen in eine Klasse von Mustern einordnen, um diese von unähnlichen Strukturen anderer Klassen von Mustern zu unterscheiden. Methoden aus der theoretischen Informatik eignen sich zur Lösung solcher Probleme [Kanal/Dattatreya 92]. Dabei werden komplexe Muster als Wörter einer Sprache aufgefaßt. Ein primitives Muster entspricht dann einem Zeichen. Grammatiken werden dann zur Beschreibung und Identifizierung von komplexen Mustern eingesetzt. Ziel ist es, eine meist große Anzahl von komplexen Mustern durch eine kleine Anzahl von primitiven Mustern und grammatikalischen Regeln zu beschreiben. Um Unsicherheiten und Ungenauigkeiten in komplexen Mustern behandeln zu können, werden häufig stochastische Grammatiken eingesetzt, oder Ähnlichkeiten zwischen komplexen

Mustern untersucht [Gonzalez/Thomason 78].

Ein syntaktisches Mustererkennungssystem besteht aus folgenden Grundbausteinen (s. Abb.7):

1. *Preprocessing, Pattern Representation und Primitive Selection*
Methoden aus der Statistik und KNN werden hier zur Gewinnung von primitiven Mustern eingesetzt. Primitive Muster sind dabei elementare Bausteine eines syntaktischen Mustererkennungssystems. Hierdurch werden die Daten in eine einfache, kompakte und für das Problem geeignete Darstellung überführt [Fu 74]. Die strukturelle Information zwischen primitiven Mustern besitzt auf dieser Ebene keine Bedeutung.
2. *Grammatical Inference*
Die strukturellen Abhängigkeiten zwischen primitiven Mustern werden durch grammatikalische Regeln beschrieben. Diese sollten möglichst einfach sein. Bei der Induktion von Grammatiken werden syntaktische Regeln einer unbekannt Grammatik aus einer endlichen Menge von Wörtern einer Sprache gewonnen. Dies ist ein sehr schwieriges Problem, da häufig keine Methode zur Induktion von Grammatiken existiert, sondern nur Heuristiken vorhanden sind. Das wesentliche Problem besteht darin, eine Grammatik zu induzieren, die nur Wörter dieser Sprache erkennt [Gonzalez/Thomason 78].
3. *Syntax Analysis*
Durch eine Syntaxanalyse werden Wörter einer Sprache, die hier komplexen Mustern entsprechen, syntaktisch überprüft. Zur Syntaxanalyse werden Parser eingesetzt [Naumann/Langer 94].

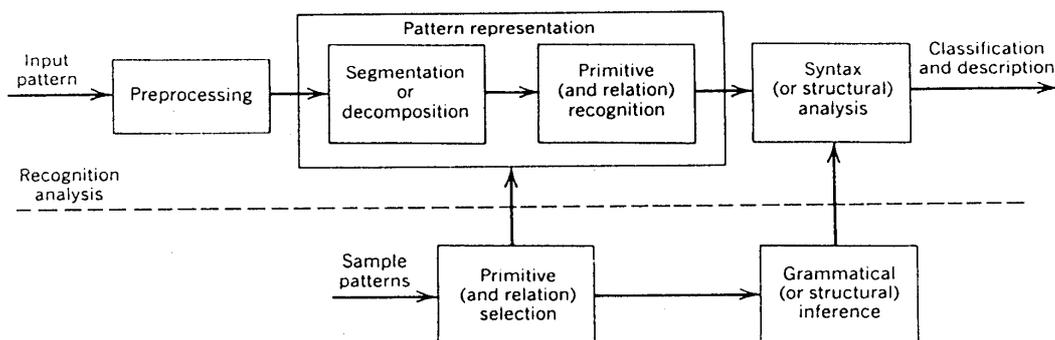


Abb.7: Grundbausteine eines syntaktischen Mustererkennungssystems (in [Kanal/Dattatreya 92]).

Kapitel 3

Eine Methode zur temporalen Wissenskonversion (TWK)

In diesem Kapitel wird eine Methode zur Entdeckung und Beschreibung von komplexen Mustern in multivariaten Zeitreihen in Form einer temporalen Wissenskonversion vorgestellt. Unter temporaler Wissenskonversion wird die Überführung von komplexen Mustern in multivariaten Zeitreihen in eine für Menschen verständliche, symbolische Wissensrepräsentation verstanden.

Ein wesentliches Ziel der im Rahmen dieser Arbeit entwickelten Methode zur temporalen Wissenskonversion (TWK) ist es, komplexe Muster in multivariaten Zeitreihen zu entdecken und auf einer symbolischen Ebene zu beschreiben. Hierzu werden durch die TWK mehrere hierarchische Abstraktionsebenen eingeführt. Dabei wird das sehr schwierige Problem der temporalen Wissenskonversion in eine Abfolge technisch behandelbarer Teilaufgaben zerlegt. Die auf den verschiedenen Abstraktionsebenen berechneten Zwischenergebnisse bilden die grundlegenden Bausteine für die Gewinnung einer symbolischen Repräsentation von komplexen Mustern in multivariaten Zeitreihen. Aus den Zwischenergebnissen der TWK werden temporale, grammatikalische Regeln erzeugt, die hier als eine temporale Grammatik (TG) bezeichnet werden. Durch die erzeugten temporalen, grammatikalischen Regeln (TG-Regeln) werden die einzelnen Schritte hin zu einer symbolischen Repräsentation nachvollziehbar.

In Kapitel 3.1 werden grundlegende Begriffe für die verschiedenen Abstraktionsebenen der TWK eingeführt. Ein Überblick über die TWK wird in Kapitel 3.2 gegeben. Hier wird u.a. veranschaulicht, daß die Überführung von Zeitreihen in eine symbolische Repräsentation eine mehrstufige Vorgehensweise erfordert. Auf den

verschiedenen hierarchischen Abstraktionsebenen, die dabei eingeführt werden, erfolgt eine zunehmende Abstraktion der multivariaten Zeitreihen im Sinne einer “gleitenden“ temporalen Wissenskonversion. Die einzelnen Schritte der TWK werden dann in Kapitel 3.3 beschrieben. In Kapitel 3.4 werden die Schritte zur Generierung einer TG aus den Zwischenergebnissen der TWK dargestellt. Dabei werden die Vorteile einer symbolischen Wissensrepräsentation durch eine TG für temporale Muster in Zeitreihen aufgezeigt.

3.1 Grundlegende Begriffe

In diesem Kapitel werden grundlegende Begriffe für die verschiedenen Abstraktionsebenen (s. Abb.13) der Methode zur temporalen Wissenskonversion (TWK) eingeführt.

Definition 3.1.1 (Multivariate) Zeitreihe

Ein Prozeß wird häufig durch einen Vektor von mehreren zeitabhängigen Größen $(x_1(t), \dots, x_m(t))^T = \vec{x}(t) \in \mathbb{R}^m$, $m \geq 1$ beschrieben. Werden diese Größen zu endlich vielen äquidistanten Zeitpunkten t_1, \dots, t_n abgetastet, so wird $Z = \vec{x}(t_1), \dots, \vec{x}(t_n)$ mit $\vec{x}(t_i) \in \mathbb{R}^m$, $m > 1$ als eine *multivariate Zeitreihe* bezeichnet.

Eine Folge von Werten $x_j(t_1), \dots, x_j(t_n)$ mit $x_j(t_i) \in \mathbb{R}$, $j \in \{1, \dots, m\}$ aus dieser multivariaten Zeitreihe Z wird als (*univariate*) *Zeitreihe* bezeichnet.

Beispiel:

Von einem Patienten mit schlafbezogenen Atmungsstörungen (SBAS) werden in einer Nacht 5 Größen aufgenommen: *Atemfluß*, *Thoraxbewegungen*, *Abdomenbewegungen*, *Schnarchgeräusche* und *Sauerstoffsättigung*. Dies stellt eine multivariate Zeitreihe (s. Abb.8) dar. Der *Atemfluß* für sich alleine ist dabei eine univariate Zeitreihe.

Werden dieselben Größen bei verschiedenen Patienten aufgenommen, so werden diese als **multivariate Zeitreihen** bezeichnet.

Bei der Verarbeitung von Zeitreihen von mehreren Patienten treten wesentliche Unterschiede in den grundlegenden Eigenschaften (z.B. Grundfrequenz, Offset, usw.) der Zeitreihen auf. Diese müssen vergleichbar gemacht werden. Hierzu werden die Zeitreihen in eine für das Problem geeignete Repräsentation überführt. Gleichzeitig werden hier wesentliche Eigenschaften der Zeitreihen extrahiert. Das Ergebnis einer Transformation von Zeitreihen in eine neue Repräsentationsform wird als *Merkmal* bezeichnet. Die Gewinnung der Merkmale heißt dann **Merkmalsextraktion**.

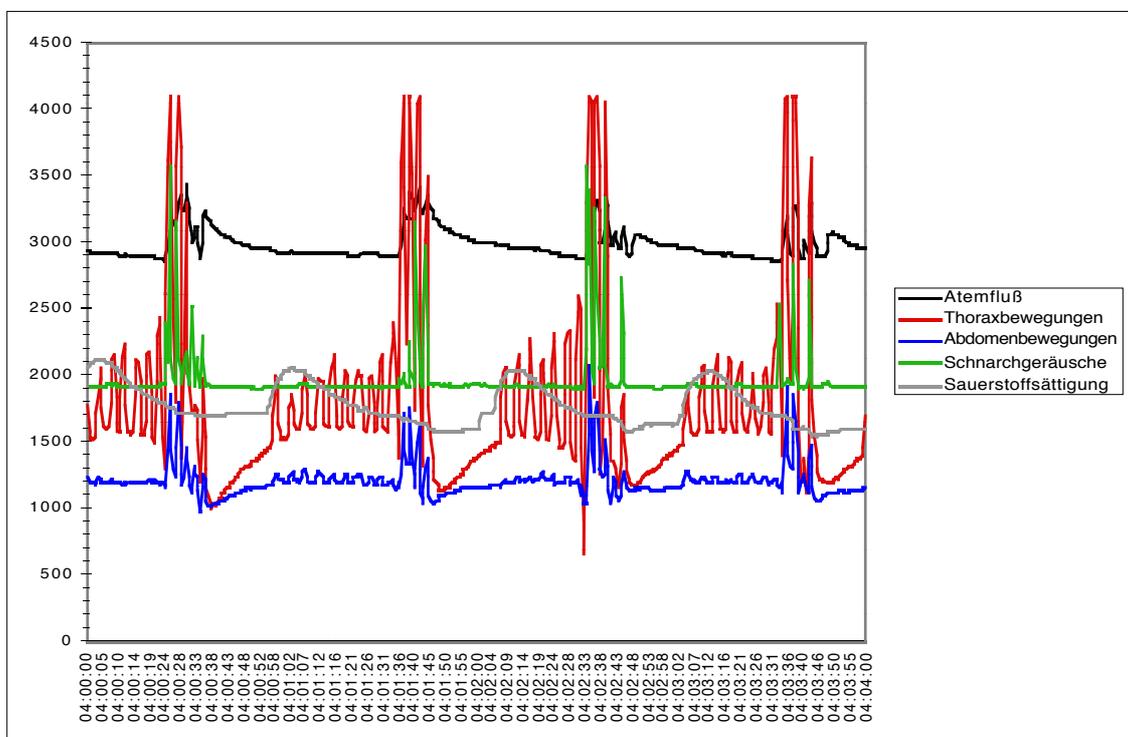


Abb.8: Multivariate Zeitreihe am Beispiel eines Patienten mit schlafbezogenen Atmungsstörungen

Definition 3.1.2 Merkmal

Sei $Z = \hat{x}(t_1), \dots, \hat{x}(t_n)$ mit $\hat{x}(t_i) \in \mathbb{R}^m$, $m > 1$ eine multivariate Zeitreihe, $S \subset \{1, \dots, m\}$, $s = |S|$ und $\hat{x}_S(t_i) = (x_{j_1}(t_i), \dots, x_{j_s}(t_i))^T \in \mathbb{R}^s$ mit $j_k \in S$, $k = 1, \dots, s$.

Der Funktionswert einer Abbildung $f : \mathbb{R}^{s \times l} \rightarrow \mathbb{R}$ heie das zum Zeitpunkt t_i mit einem Zeitfenster $l \in \{1, \dots, n-1\}$ aus der Selektion S bestimmtes

Merkmal $m_S(t_i, l) = f(\hat{x}_S(t_i), \dots, \hat{x}_S(t_{i+l}))$ bezuglich der Abbildung f .

Bei der Erkennung von SBAS spielt eine groe Rolle, ob die Thorax- und Abdomenbewegungen parallel oder phasenverschoben (gegenlufig) verlaufen. Daher wird als Beispiel fur ein Merkmal die Phase zwischen den Thorax- und Abdomenbewegungen bestimmt (s. Kapitel 5.2.1). Dieses Merkmal wird als *ThoraxAbdomen-Phase* bezeichnet (s. Abb.9). Die Zeitreihen *Thoraxbewegungen* und *Abdomenbewegungen* sind die zur Berechnung des Merkmals verwendete Selektion.

Eine **Merkmalsfolge** sind die zu allen moglichen Zeitpunkten berechneten Merkmale aus einer Selektion. Die aus mehreren Selektionen berechneten Merkmalsfolgen heien **multivariate Merkmalsfolge**. In der Regel werden aus einer multivariaten Merkmalsfolge einzelne Merkmale zur Strukturanalyse (s. Kapitel 2.1.2) selektiert. Man spricht dann von einer **Selektion von Merkmalen**.

In dem Beispiel des Patienten mit SBAS werden 12 Merkmalsfolgen aus der multivariaten Zeitreihe berechnet (s. Abb.9). Diese bilden eine multivariate Merkmalsfolge. Die Gewinnung der Merkmale wird in Kapitel 5.2.1 beschrieben. Zur Strukturanalyse werden Merkmale selektiert, die von der Anwendung her untereinander Abhangigkeiten aufweisen. Eine Selektion von Merkmalen erhlt man z.B. durch Auswahl der Merkmale *Thorax-stark*, *Thorax-reduziert*, *Thorax-kein*, *Abdomen-stark*, *Abdomen-reduziert*, *Abdomen-kein*, *Thorax-Abdomen-Phase*, *Schnarchintensitt*.

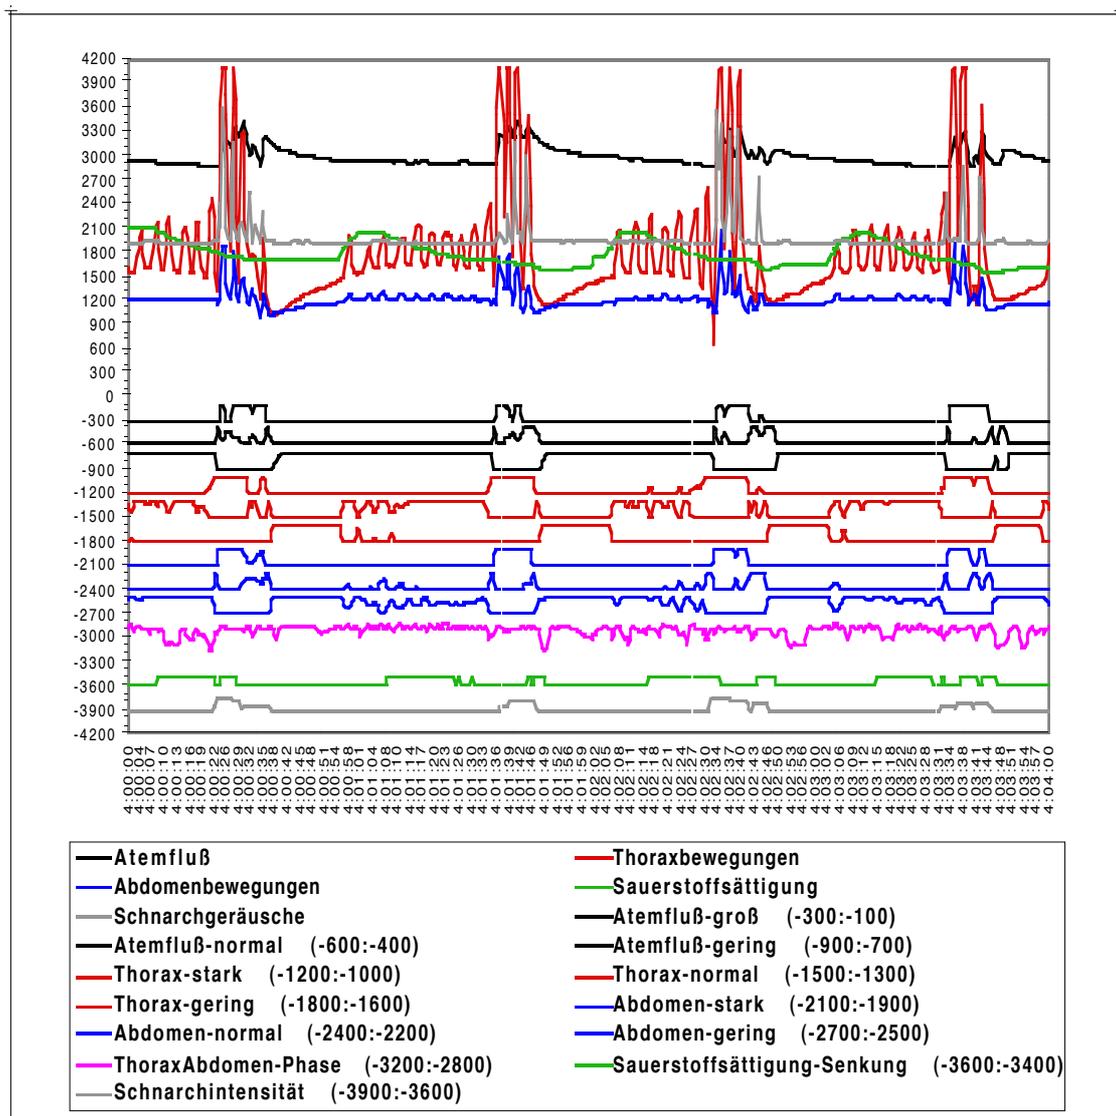


Abb.9: Multivariate Zeitreihe und multivariate Merkmalsfolge am Beispiel eines Patienten mit schlafbezogenen Atmungsstörungen

Durch eine Strukturanalyse werden Selektionen von Merkmalen einer Klasse zugeordnet. Jede Klasse wird dann als *PrimitivePattern-Klasse* bezeichnet. Ein *PrimitivePattern* ist ein zu einem bestimmten Zeitpunkt auftretendes Element einer *PrimitivePattern-Klasse*. Ziel einer Strukturanalyse ist es, Zeitreihen auf ihre wesentlichen Charakteristika zu reduzieren. An dieser Stelle findet ein erster semantischer Übergang in der temporalen Wissenskonversion statt. *PrimitivePatterns* können als primitive Muster in Zeitreihen auf elementarster Ebene betrachtet werden.

Definition 3.1.3 PrimitivePattern (-Klasse)

Sei T eine aus einer multivariaten Zeitreihe $Z = \vec{x}(t_1), \dots, \vec{x}(t_n)$ mit $\vec{x}(t_i) \in \mathbb{R}^m$, $m > 1$ gewonnene Selektion von Merkmalen.

Werden die durch eine Selektion T bestimmten Merkmalsvektoren $\{m_T(t_i, l) \mid i = 1, \dots, n - l\}$ durch eine Strukturanalyse in v Klassen eingeteilt, so kann jeder Merkmalsvektor $\vec{m}_T(t_i, l)$ ggf. einer Klasse p_j , $j \in \{1, \dots, v\}$ zugeordnet werden. Eine Klasse p_j , $j \in \{1, \dots, v\}$ wird dann als *PrimitivePattern-Klasse* mit Namen 'j' bezeichnet.

$p_j(t_i)$ wird als zum Zeitpunkt t_i auftretendes *PrimitivePattern* in Z mit Namen 'j' bezeichnet.

Selektionen von Merkmalen, die keiner PrimitivePattern-Klasse zugeordnet werden, werden einer besonderen Klasse zugeordnet. Diese Klasse wird nach einem Vorschlag von A. Ultsch als **Tacet**¹ bezeichnet. Werden PrimitivePatterns durch die U-Matrix-Methode (s. Kapitel 2.1.2) bestimmt, so werden die Bestmatches, hier PrimitivePatterns, die auf Bereiche der U-Matrix fallen, die keiner PrimitivePattern-Klasse zugeordnet wurden, der Klasse Tacet zugeordnet.

Die zu allen möglichen Zeitpunkten aus einer Selektion von Merkmalen bestimmten PrimitivePatterns und Tacets sind eine **PrimitivePattern-Folge**. Mehrere PrimitivePattern-Folgen aus verschiedenen Selektionen von Merkmalen sind eine **multivariate PrimitivePattern-Folge**.

Dies sei an einem Beispiel erläutert. Zur Strukturanalyse werden zwei Selektionen von Merkmalen nach anwendungsabhängigen Kriterien bestimmt: (a) Merkmale, die im wesentlichen den Atemfluß beeinflussen, wie *Atemvolumen-groß*, *Atemvolumen-reduziert*, *Atemvolumen-kein*, *ThoraxAbdomen-Phase*, *Schnarchintensität* und (b) Merkmale, die im wesentlichen die Thorax- und Abdomenbewegungen beeinflussen, wie *Thorax-stark*, *Thorax-reduziert*, *Thorax-kein*, *Abdomen-stark*, *Abdomen-reduziert*, *Abdomen-kein*, *ThoraxAbdomen-Phase*, *Schnarchintensität*. Durch eine Strukturanalyse werden aus beiden Selektionen von Merkmalen zwei PrimitivePattern-Folgen bestimmt (s. Abb.10). Diese bilden eine multivariate Pri-

1. Dieser Begriff stammt aus der Musik und bedeutet das Schweigen eines Instrumentes oder einer Stimme.

mitivePattern-Folge. Die Bestimmung der PrimitivePatterns erfolgt anhand von zwei U-Matrizen (s. Kapitel 5.2.2). Bereiche auf den U-Matrizen, die keinem PrimitivePattern zugeordnet werden, gehören der Klasse Tacet an.

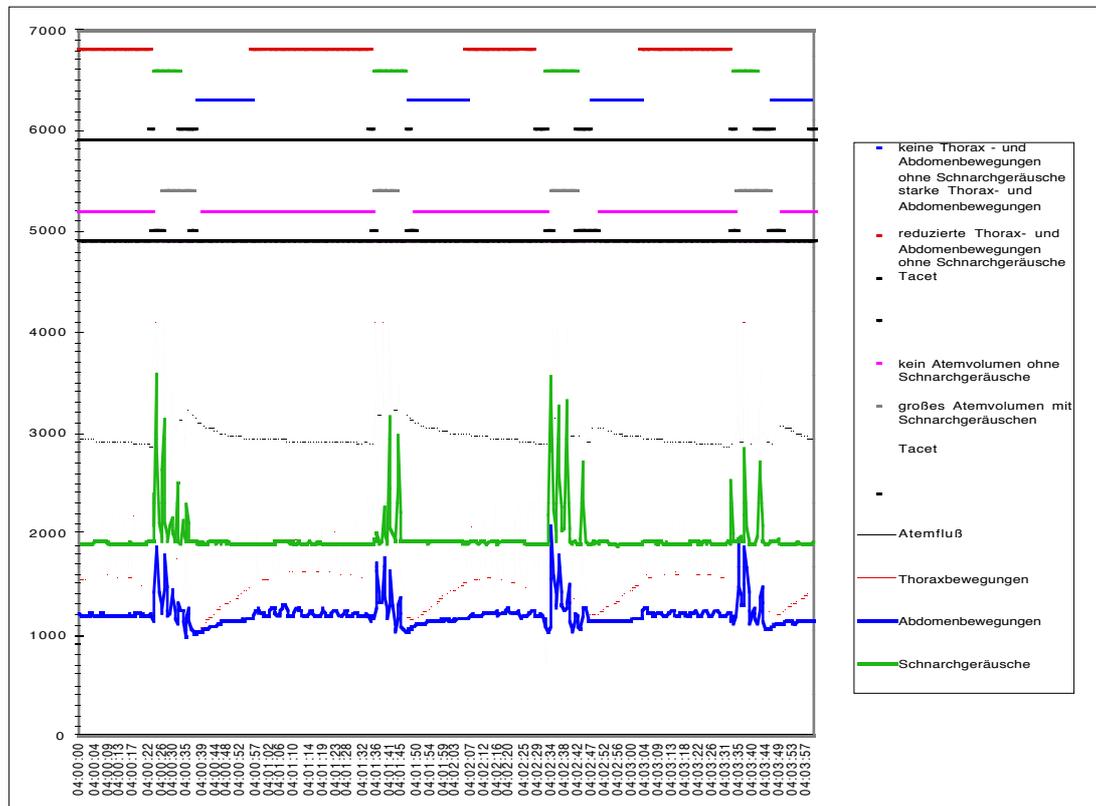


Abb.10: Multivariate Zeitreihe und multivariate Primitive-Pattern-Folge am Beispiel eines Patienten mit schlafbezogenen Atmungsstörungen.

Jedem PrimitivePattern wird ein Name zugeordnet (s. Kapitel 5.2.2), der aus den durch den Regelgenerierungsalgorithmus sig* erzeugten Regeln [Ultsch 91] abgeleitet wird. Durch die sig*-Regeln werden PrimitivePatterns durch ihre signifikanten Merkmale beschrieben. Z.B. wird ein PrimitivePattern als *großes Atemvolumen* bezeichnet, falls das Merkmal *Atemvolumen-stark* hohe Werte annimmt, wobei der Wertebereich des Merkmals *Atemvolumen-stark* im Intervall von $[0,1]$ liegt. Dabei bedeuten hohe Werte, daß das Merkmal höchstwahrscheinlich vorkommt und niedrige Werte, daß das Merkmal eher nicht auftritt.

Beispiel:

Ein PrimitivePattern ist ein

großes Atemvolumen

falls

Atemvolumen-stark **in** [0.3697, 1]

Für die Strukturanalyse haben die Zeitpunkte, an denen PrimitivePatterns auftreten, keine Rolle gespielt. Um PrimitivePatterns in einem zeitlichen Kontext zu betrachten, werden unmittelbar aufeinanderfolgende gleiche PrimitivePatterns zu einer neuen Einheit zusammengefaßt. Diese neue Einheit wird als *Succession* bezeichnet. Jeder Succession wird dann der Name der in der Succession auftretenden PrimitivePatterns gegeben.

Definition 3.1.4 Succession

Sei $p_j(t_k)$ ein aus einer multivariate Zeitreihe $Z = \hat{x}(t_1), \dots, \hat{x}(t_n)$ mit $\hat{x}(t_i) \in \mathbb{R}^m$, $m > 1$ bestimmtes PrimitivePattern mit Namen 'j' zum Zeitpunkt t_k . Eine zu unmittelbar aufeinanderfolgenden Zeitpunkten t_k, \dots, t_{k+l} bestehende Folge von gleichen PrimitivePatterns $p_j(t_i)$, $i = k, \dots, k+l$, $l \in \{1, \dots, n-k\}$ in Z heiße *Succession* $s(a, e)$ in Z mit Namen 'j', wobei $a := t_k$ der Anfangszeitpunkt, $e := t_{k+l}$ der Endzeitpunkt und $l = e - a$ die Dauer der Succession ist.

Treten in einer PrimitivePattern-Folge unmittelbar aufeinanderfolgende Tacets auf, so werden sie ebenfalls als **Tacet** bezeichnet.

Beispiele für Successions in dem Beispiel des Patienten mit SBAS werden in Abb.10 graphisch dargestellt. Eine Succession entspricht dabei unmittelbar aufeinanderfolgende gleiche PrimitivePatterns wie z.B. das PrimitivePattern *kein Atemvolumen ohne Schnarchgeräusche* und besitzt dadurch eine bestimmte Dauer. Durch diese Darstellung ist eine multivariate Zeitreihe durch mehrere Folgen von Successions repräsentiert, wobei Successions direkt aufeinanderfolgen oder durch ein Tacet getrennt aufeinanderfolgen können. Ziel ist es dabei, *ungefähr gleichzeitig auftretende Successions* in einer multivariaten PrimitivePattern-Folge zu identifizieren.

Definition 3.1.5 zeitlich überlappende Successions

Seien $s_1(a_1, e_1)$ und $s_2(a_2, e_2)$ Successions. $s_1(a_1, e_1)$ und $s_2(a_2, e_2)$ sind *zeitlich überlappend*, falls $e_1 > a_2$ und $e_2 > a_1$ gilt.

Definition 3.1.6 ungefähr gleichzeitig auftretende Successions

Seien $s_1(a_1, e_1), \dots, s_q(a_q, e_q)$ paarweise zeitlich überlappende Successions. Die Successions $s_1(a_1, e_1), \dots, s_q(a_q, e_q)$ *treten ungefähr gleichzeitig auf*, falls für $\varepsilon, \delta \in]0, 0.1]$ gilt: $\frac{|\max(a_i) - \min(a_i)|}{l} < \varepsilon$ und $\frac{|\max(e_i) - \min(e_i)|}{l} < \delta, i = 1, \dots, q$ mit $l = \min(e_i) - \max(a_i)$.

In Abb.11 werden zwei ungefähr gleichzeitig auftretende Successions graphisch dargestellt, wobei A Anfangszeitpunkt und E Endzeitpunkt des gleichzeitigen Auftretens der Successions *großes Atemvolumen mit Schnarchgeräuschen* [4:00:22, 4:00:36] und *starke Thorax- und Abdomenbewegungen* [4:00:24, 4:00:40] sind. Die Dauer der ungefähr gleichzeitigen Successions ist dann durch $l = E - A = 12$ sec gegeben. Die Zeitpunkte 4:00:22 und 4:00:24 sind dabei die Anfangszeitpunkte und die Zeitpunkte 4:00:36 und 4:00:40 die Endzeitpunkte der Successions.

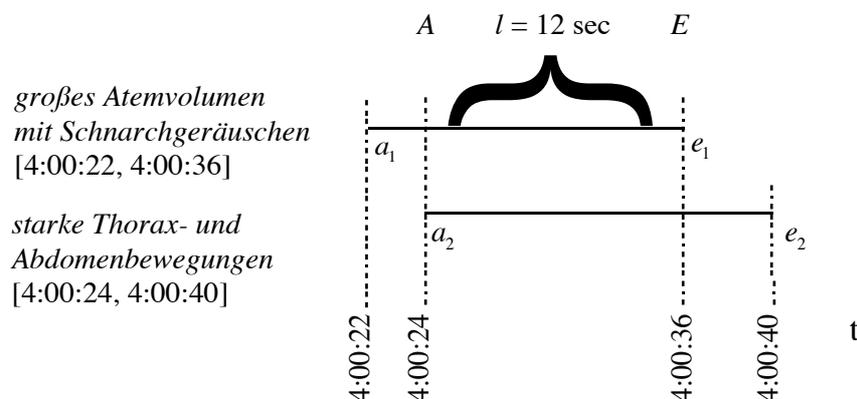


Abb.11: Beispiel für zwei ungefähr gleichzeitig auftretende Successions.

Ungefähr gleichzeitig auftretende Successions werden zu einer neuen Einheit zusammengefaßt. Diese neue Einheit wird als *Event* bezeichnet. Dabei wird jedem Event ein Name 'e' gegeben.

Auf dieser Ebene findet ein weiterer semantischer Übergang in der temporalen Wissenskonversion statt. Durch Events werden besonders ausgezeichnete Ereignisse in einer multivariaten Zeitreihe erkannt. Da jedem Event ein Name (Symbol) zur Bezeichnung des Events gegeben wird, ist eine multivariate Zeitreihe auf dieser Abstraktionsebene durch eine Folge von Symbolen, den Events, repräsentiert.

Definition 3.1.7 Event

Seien $s_1(a_1, e_1), \dots, s_q(a_q, e_q)$ ungefähr gleichzeitig auftretende Successions, $A = \max(a_1, \dots, a_q)$, $E = \min(e_1, \dots, e_q)$ und $l = E - A$.

Falls in $s_1(a_1, e_1), \dots, s_q(a_q, e_q)$ höchstens $q - 1$ Tacets auftreten, werden sie als *Event* $e(l)$ bezeichnet, wobei A der Anfangszeitpunkt, E der Endzeitpunkt und l die Dauer des Events ist.

Dabei können dieselben Events, d.h. Events in denen dieselben Successions ungefähr gleichzeitig auftreten, zu verschiedenen Zeitpunkten eine unterschiedliche Dauer besitzen.

In Abb.11 werden zwei ungefähr gleichzeitig auftretende Successions *große Atemvolumen mit Schnarchgeräuschen* und *starke Thorax und Abdomenbewegungen* dargestellt. Diese sind dann ein Event. Der Anfangszeitpunkt des Events ist in diesem Beispiel 4:00:24, der Endzeitpunkt ist 4:00:36 und die Dauer der Events beträgt 12 sec.

In einem Event dürfen Successions auch mit Tacets ungefähr gleichzeitig auftreten. Treten jedoch nur Tacets ungefähr gleichzeitig auf, so werden diese besonders ausgezeichnet und als **EventTacet** bezeichnet. EventTacets stellen somit eine Unterbrechung bzw. eine Pause zwischen zwei aufeinanderfolgenden Events dar.

Im Beispiel des Patienten mit SBAS kommen 3 Events vor: *Event2*, *Event3* und *Event5* (s. Abb.12). Die Events werden durch das ungefähr gleichzeitige Auftreten von Successions aus zwei PrimitivePattern-Folgen bestimmt (s. Abb.10).

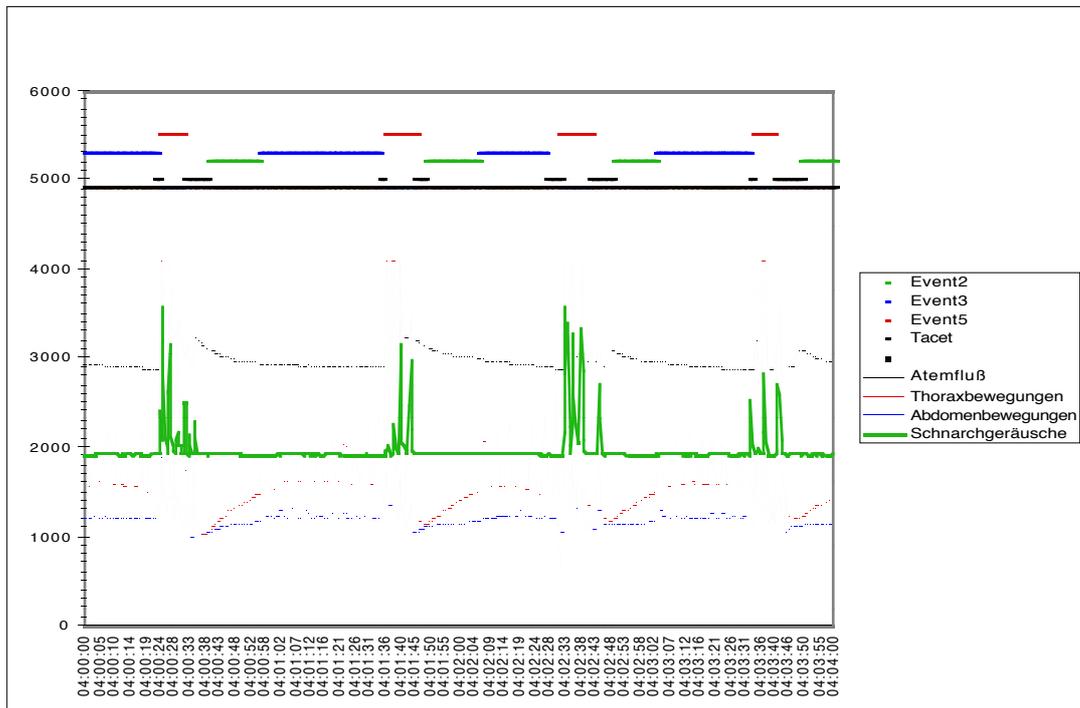


Abb.12: Multivariate Zeitreihe, Events und EventTacets am Beispiel eines Patienten mit schlafbezogenen Atmungsstörungen

Auf dieser Abstraktionsebene werden für Events grammatikalische Regeln erzeugt, die eine symbolische Wissensrepräsentation der Events sind. Diese werden als TG¹-Regeln bezeichnet. Zur Beschreibung der ungefähr gleichzeitig auftretenden Successions in den TG-Regeln für die Events wird das Sprachkonstrukt ‘**ist ungefähr gleichzeitig mit**’ eingeführt. Alternativen zwischen mehreren ungefähr gleichzeitig auftretenden Successions in einem Event werden durch das Sprachkonstrukt ‘**oder**’ beschrieben. Hier wird die Bedeutung der durch die sig*-Regeln abgeleiteten Namen für PrimitivePatterns und daher auch für Successions ersichtlich. Einerseits kann dadurch ein bedeutungsvoller Name für die Events hergeleitet werden, der auf der nächst höheren Ebene zur Beschreibung von Sequences (s.u.) weiter verwendet werden kann. Andererseits ist anhand der TG-Regeln, die eine inhaltliche Beschreibung der Events in einer sprachlichen Form sind, eine Interpretation und Beurteilung der Events durch einen medizinischen Experten möglich.

1. TG ist eine Abkürzung für temporale Grammatik.

Im folgenden wird am Beispiel von *Event5* erklärt, wie ein Name für ein Event aus einer TG-Regel hergeleitet werden kann.

Beispiel:

Ein Event ist ein

Event5

falls

(*großes Atemvolumen mit Schnarchgeräuschen*

oder

reduziertes Atemvolumen mit Schnarchgeräuschen)

ist ungefähr gleichzeitig mit

starke Thorax- und Abdomenbewegungen

Bei *Event5* tritt entweder die Succession *großes Atemvolumen mit Schnarchgeräuschen* oder die Succession *reduziertes Atemvolumen mit Schnarchgeräuschen* mit der Succession *starke Thorax- und Abdomenbewegungen* ungefähr gleichzeitig auf. Da hauptsächlich die Successions *großes Atemvolumen mit Schnarchgeräuschen* und *starke Thorax- und Abdomenbewegungen* in *Event5* vorkommen (s. Anhang A.7), werden diese zur Ableitung eines bedeutungsvollen Namens für *Event5* verwendet. *Event5* wird daher der Name *starke Atmung mit Schnarchgeräuschen* gegeben.

Folgende Namen werden durch eine solche Vorgehensweise für die Events des Beispiels hergeleitet:

- *Event2: kein Atemvolumen und keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche*
- *Event3: kein Atemvolumen und reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche*
- *Event5: starke Atmung mit Schnarchgeräuschen*

Aufeinanderfolgende Events und EventTacets aus einer multivariaten Zeitreihe Z sind eine **Eventfolge**. Die Dauer einer gegebenen Eventfolge entspricht der Summe über die Dauer der Events und EventsTacets in der Eventfolge. Da Events durch Symbole repräsentiert sind, wird auf dieser Abstraktionsebene eine multivariate Zeitreihe als eine Folge von Symbolen beschrieben. Jedes Event (Symbol) besitzt dabei eine bestimmte Dauer.

Eine Teilfolge in einer Eventfolge, die wiederholt auftritt, wird als *Sequence* bezeichnet. Jeder Sequence wird ein Name 's' gegeben. Sequences werden durch *Startevents* und *Endevents* identifiziert. Startevents bzw. Endevents sind eine Teilmenge der Events, mit denen Sequences starten bzw. enden. Da dieselben Events in einer Sequence zu unterschiedlichen Zeitpunkten eine voneinander abweichende Dauer besitzen können, wird für jedes Event in einer Sequence eine minimale und eine maximale Dauer angegeben.

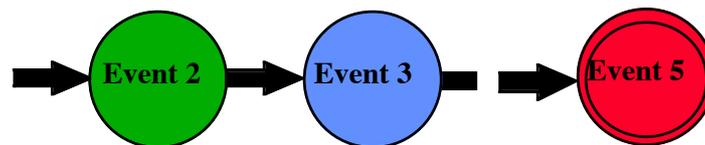
Definition 3.1.8 Sequence

Sei F eine Eventfolge aus einer multivariaten Zeitreihe Z und sei e_1, \dots, e_k eine Teilfolge von Events, die mehrmals in F auftritt, wobei die Dauer jedes Events bei den Wiederholungen variieren kann.

Tritt die Teilfolge e_1, \dots, e_k in F m -mal, $m > 1$ auf, so wird sie als Sequence $sq(min, max) = e_1(min_1, max_1), \dots, e_k(min_k, max_k)$ bezeichnet, wobei min_i die kürzeste Dauer und max_i die längste Dauer der Events e_i für alle in F auftretenden Teilfolgen $M(e_1, \dots, e_k)$ ist, min die Dauer des kürzesten Auftretens und max die Dauer des längsten Auftretens von e_1, \dots, e_k in F ist.

Auf dieser Abstraktionsebene werden für Sequences grammatikalische Regeln erzeugt, die eine symbolische Wissensrepräsentation der Sequences sind. Diese werden auch als TG-Regeln bezeichnet. Durch TG-Regeln für Sequences werden aufeinanderfolgende Events einer Sequence, möglicherweise mit einer Unterbrechung durch ein EventTacet, in einer für Menschen verständlichen, sprachlichen Form beschrieben. Hierzu werden die Sprachkonstrukte '**gefolgt von**' und '**gefolgt nach** [*'Dauer des EventTacet'*]' **von**' eingeführt. Da ein für die Anwendung ggf. bedeutsamer Name für die Events existiert, kann möglicherweise die Bedeutung der Sequences für die Anwendung anhand der TG-Regeln durch einen medizinischen Experten beurteilt werden.

Für das Beispiel des Patienten mit SBAS werden 3 Events einer Sequence identifiziert, die folgendermaßen graphisch dargestellt werden können. Dabei entsprechen direkte Pfeile unmittelbar aufeinanderfolgende Events und Pfeile mit Unterbrechung aufeinanderfolgende Events, die durch ein EventTacet unterbrochen werden.



Eine TG-Regel für das Beispiel sieht wie folgt aus:

Eine Sequence ist eine

SequenceA [40 bis 64 sec]

falls

Event 2: kein Atemvolumen und keine Thorax und Abdomenbewegungen ohne Schnarchgeräusche [13 bis 18 sec]

gefolgt von

Event 3: kein Atemvolumen und reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche [20 bis 39 sec]

gefolgt nach [0,5 bis 5 sec] von

Event 5: starke Atmung mit Schnarchgeräuschen
[6 bis 12 sec]

Die in einer multivariaten Zeitreihe auftretenden Sequences weisen einen unterschiedlichen Grad an Ähnlichkeit auf. Ähnlichkeiten von Sequences werden analog aufgefaßt zu Ähnlichkeiten von Strings [Ultsch 87] und können durch den Einsatz von Stringaustauschalgorithmus bestimmt werden. Treten ähnliche Sequences in einer multivariaten Zeitreihe auf, so werden diese zu einem *TemporalPattern* zusammengefaßt. Ein *TemporalPattern* besteht dadurch ggf. aus Alternativen von Sequences. Ein *TemporalPattern* kann auch nur aus einer Sequence bestehen. Jedem *TemporalPattern* wird ein Name 'p' gegeben.

Definition 3.1.9 TemporalPattern

Sei Z eine multivariate Zeitreihe und seien $sq_1(min_1, max_1), \dots, sq_v(min_v, max_v)$ ähnliche Sequences in Z .

Eine Alternative der Sequences $sq_1(min_1, max_1) \vee \dots \vee sq_v(min_v, max_v)$ in Z wird als *TemporalPattern* $tp(min, max)$ bezeichnet.

Dabei ist $min = \min(min_1, \dots, min_v)$ die minimale und $max = \max(max_1, \dots, max_v)$ die maximale Dauer des TemporalPatterns.

Ähnliche Sequences in TemporalPatterns werden in TG-Regeln durch das Sprachkonstrukt ‘**oder**’ beschrieben. Da im Beispiel des Patienten mit SBAS das TemporalPattern aus nur einer Sequence besteht, besteht die rechte Seite der TG-Regel aus nur einer Sequence (s. Kapitel 5.2.7).

3.2 Überblick über die Methode

In diesem Kapitel wird ein Überblick über die einzelnen Schritte der Methode zur temporalen Wissenskonversion (TWK) gegeben.

Es ist ein wesentliches Ziel der hier entwickelten Methode, eine Brücke zwischen verschiedenen Wissensrepräsentationen für Zeitreihen zu schlagen. Auf den durch die TWK eingeführten verschiedenen Abstraktionsebenen wird eine zunehmende symbolische Beschreibung im Sinne einer "gleitenden" temporalen Wissenskonversion erreicht. Das heißt, die Überführung erfolgt nicht ad hoc, sondern in mehreren kleinen Schritten. Die Motivation hierfür liegt in der Zerlegung eines im Prinzip sehr schwierigen Problems in einzelne technisch lösbare Teilaufgaben.

In Abb.13 sind die wesentlichen Schritte dargestellt, die bei der TWK durchgeführt werden. Auf den verschiedenen Abstraktionsebenen werden die Zwischenergebnisse der einzelnen Schritte der TWK ermittelt. Dadurch können auf verschiedenen Ebenen einzelne Schritte wiederholt und optimiert werden. Die Zwischenergebnisse der TWK sind weiterhin grundlegende Bausteine für die Gewinnung einer symbolischen Beschreibung in Form einer temporalen Grammatik (TG) für die in Zeitreihen entdeckten komplexen Muster (s. Kapitel 3.4).

Eingabe in das System sind multivariate Zeitreihen. Als Ergebnis werden TG-Regeln für TemporalPatterns, Sequences und Events sowie sig*-Regeln für PrimitivePatterns ausgegeben. Eine Interaktion mit einem Experten für die Anwendung erfolgt nur dann, wenn eine Interpretation der Zwischenergebnisse für eine Weiterverarbeitung oder eine Überprüfung der Zwischenergebnisse erforderlich ist. Im folgenden werden die einzelnen Schritte der TWK und die Gewinnung einer TG aus den Zwischenergebnissen der TWK beschrieben.

Zur Erkennung von Sequences bzw. TemporalPatterns werden die folgenden Annahmen getroffen:

1. *In den multivariaten Zeitreihen existieren komplexe Muster.*
Die Erkennung von Strukturen ist nur dann möglich, falls in den Daten überhaupt zu entdeckende Strukturen enthalten sind [Hartung 91].

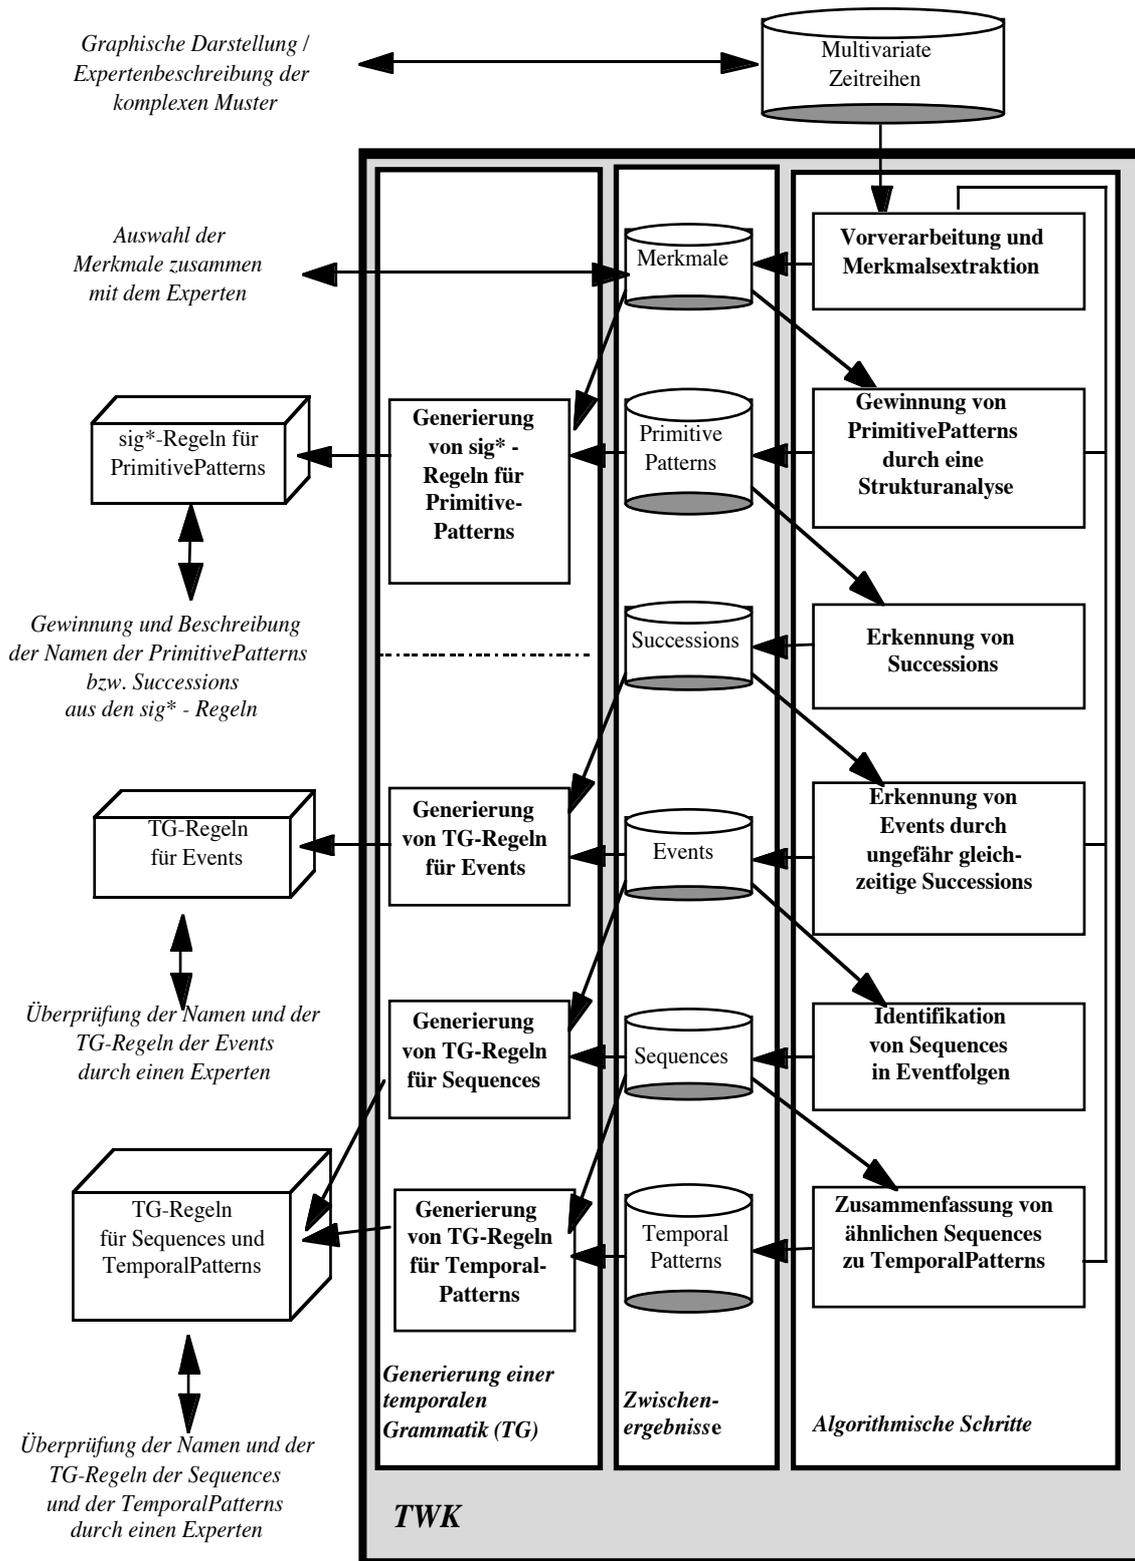


Abb.13: Schritte der Methode zur temporalen Wissenskonzersion (TWK)

2. *Die Anzahl verschiedener Typen von Ereignissen bzw. Events in komplexen Mustern ist hinreichend klein.*
Events entsprechen charakteristischen Ereignissen in multivariaten Zeitreihen. Daher werden Events nur dann als solche identifiziert, falls sie sehr häufig in multivariaten Zeitreihen auftreten. Weniger häufige Events werden den sehr häufigen Events zugeordnet. Alle anderen Zeitbereiche entsprechen EventFacets. Demzufolge ist die Anzahl unterschiedlicher Events hinreichend klein.
3. *In den multivariaten Zeitreihen treten komplexe Muster wiederholt auf.*
Dabei wird von Prozessen ausgegangen, die mehrere Zustände durchlaufen. Wird ein Prozeß lange genug beobachtet, so wiederholen sich typische Prozeßverläufe, die hier als komplexe Muster beobachtbar sind.
4. *Die Anzahl verschiedener Typen von komplexen Mustern in multivariaten Zeitreihen ist hinreichend klein.*
Für die Entdeckung von komplexen Mustern in multivariaten Zeitreihen wird nach Annahme 3 ein wiederholtes Auftreten komplexer Muster vorausgesetzt. Bei begrenztem Beobachtungszeitraum bzw. Signalaufnahme ist daher die Anzahl komplexer Muster beschränkt.

Im folgenden wird ein Überblick über die verschiedenen Schritte der TWK gegeben.

Vorverarbeitung und Merkmalsextraktion

Ziel einer Merkmalsextraktion ist es, wesentliche *Merkmale* aus Zeitreihen zu extrahieren, so daß eine Überführung der Zeitreihen in eine für das Problem adäquate Repräsentation erfolgen kann [Niemann 90, Bishop 95]. Dabei können u.a. Verfahren aus Statistik [Bishop 95, Fukunaga 90], Signalverarbeitung [Masters 93] und Fuzzy-Theorie [Kosko 92, Pao 89] eingesetzt werden.

Gewinnung von PrimitivePatterns durch eine Strukturanalyse

Durch eine Strukturanalyse werden in diesem Schritt in einer Menge von ausgewählten Merkmalen (Selektionen) zu allen möglichen Zeitpunkten ggf. Klassen identifiziert, die als PrimitivePattern-Klassen bezeichnet werden. Den PrimitivePattern-Klassen werden Namen gegeben. Kann eine Selektion von Merkmalen zu einem bestimmten Zeitpunkt t einer PrimitivePattern-Klasse mit Namen 'p' zugeordnet werden, so wird das als das Auftreten des *PrimitivePattern* mit Namen 'p' zum Zeitpunkt t bezeichnet.

Selektionen von Merkmalen, die keiner PrimitivePattern-Klasse zugeordnet werden können, gehören einer besonderen Klasse an. Diese Klasse wird als *Tacet* bezeichnet.

Als Verfahren zur Strukturanalyse eignen sich u.a. Verfahren der Clusteranalyse sowie künstliche neuronale Netze mit unüberwachtem Lernverfahren. Insbesondere eignen sich hierzu selbstorganisierende Merkmalskarten nach dem Modell von Kohonen (1984), die durch eine geeignete visuelle Darstellung der angelernen Netzstruktur durch eine der U-Matrix-Methoden eine Strukturanalyse ermöglichen [Ultsch 92] (s. Kapitel 2.1.2).

Auf dieser Ebene findet ein erster semantischer Übergang in der temporalen Wissenskonversion statt, da nun multivariate Zeitreihen durch mehrere Folgen von PrimitivePatterns repräsentiert sind, die durch eine oder mehrere Strukturanalysen bestimmt werden.

Generierung von sig*-Regeln für PrimitivePatterns

Im Rahmen dieser Arbeit wird vorgeschlagen, bedeutungsvolle Namen für PrimitivePatterns aus den durch den Regelgenerierungsalgorithmus sig* [Ultsch 91] erzeugten Regeln abzuleiten. Durch eine sig*-Regel wird jede PrimitivePattern-Klasse durch ihre signifikanten Merkmale beschrieben. Durch Interpretation der Merkmale anhand der Regeln kann ggf. ein für die Anwendung bedeutsamer Name für PrimitivePattern-Klassen und somit auch für PrimitivePatterns hergeleitet werden.

Erkennung von Successions

Eine *Succession* mit Namen 's' ist eine aus unmittelbar aufeinanderfolgenden Zeitpunkten bestehende Folge von gleichen PrimitivePatterns mit dem selben Namen 's'. Im Gegensatz zu PrimitivePatterns besitzen Successions daher eine Dauer.

Eine Succession wird durch ihren Start- und Endzeitpunkt identifiziert. Werden PrimitivePatterns durch eine U-Matrix bestimmt, so können Successions durch Wege auf U-Matrizen dargestellt und ggf. erkannt werden (s. Kapitel 4.3).

Erkennung von Events durch ungefähr gleichzeitig auftretende Successions

Ungefähr gleichzeitig auftretende Successions werden zu einem *Event* zusammengefaßt. Events in einer Eventfolge, die aus denselben ungefähr gleichzeitigen

Successions bestehen, wird ein und derselbe Name ‘e’ gegeben. Treten ausschließlich Tacets ungefähr gleichzeitig auf, so werden sie als *EventTacet* bezeichnet.

Da bestimmte Events häufiger als andere auftreten können, kann ggf. zwischen sehr häufigen und weniger häufigen Events unterschieden werden. Events, in denen PrimitivePatterns sehr häufig gleichzeitig auftreten, werden als die “eigentlichen“ Events aufgefaßt. Alle anderen Events, die weniger häufig auftreten, werden den sehr häufig auftretenden Events zugeordnet (s. a. Kapitel 5.2.4).

Die Erkennung von Events kann außerdem durch den Einsatz von hierarchischen SOM erfolgen (s. Kapitel 4.2). Dabei werden Events durch eine U-Matrix auf der zweiten Schicht einer hierarchischen SOM bestimmt. Unterschiedlich häufige Events können anhand der Größe der “Täler“ auf einer U-Matrix erkannt werden.

Auf dieser Abstraktionsebene findet ein weiterer semantischer Übergang in der temporalen Wissenskonversion statt, da durch die Events wesentliche Ereignisse in einer multivariaten Zeitreihe auf einer symbolischen Ebene beschrieben werden.

Generierung von TG-Regeln für Events

In diesem Schritt werden aus den bisher gewonnenen Zwischenergebnissen der TWK TG-Regeln erzeugt, die eine sprachliche Beschreibung der Events in Form einer symbolischen Wissensrepräsentation liefern. Zur Generierung von TG-Regeln werden die Sprachkonstrukte ‘oder’ und ‘ist ungefähr gleichzeitig mit’ eingeführt. Aus den TG-Regeln können ggf. bedeutungsvolle Namen für Events hergeleitet werden.

Identifikation von Sequences in Eventfolgen

Sequences sind Teilfolgen in einer Eventfolge, die in der Eventfolge wiederholt auftreten. Dabei wird jeder Sequence ein Name gegeben. Das erste Event einer Sequence wird als *Start-event* und das letzte Event als *Endevent* bezeichnet. Da dieselben Events einer Sequence mit Namen ‘s’ zu verschiedenen Zeitpunkten eine voneinander abweichende Dauer haben können, wird für jedes Event der Sequence eine minimale und eine maximale Dauer angegeben. Eine Sequence besitzt damit auch eine minimale und eine maximale Dauer.

Einen ersten Hinweis für die Identifikation von Sequences können z. B. stochastischen Automaten liefern [Bukharaev 95]. Zustandsübergänge eines Automaten

entsprechen Übergängen zwischen Events. Zyklen in einem stochastischen Automaten werden als mögliche Sequences betrachtet.

Einen weiteren Hinweis für Sequences liefern Startevents und Endevents. Zur Erkennung von Startevents und Endevents werden länger andauernde EventTacets bestimmt. Events, die häufig nach bzw. vor einem länger andauernden EventTacet auftreten, werden als Startevents bzw. Endevents identifiziert. Da Events als eine Einheit aufgefaßt werden, können sie durch ein Zeichen dargestellt werden. Eine Eventfolge ist dann eine Zeichenkette (String). Durch Identifizierung besonderer Zeichen, den Startevents und den Endevents, kann der String in Substrings zerlegt werden. Substrings entsprechen dann Sequences.

Generierung von TG-Regeln für Sequences

Für jede Sequence wird aus den bisherigen Zwischenergebnissen der TWK eine TG-Regel erzeugt, die eine sprachliche Beschreibung einer Sequence in Form einer symbolischen Wissensrepräsentation liefert. Dabei werden Sequences als Folgen von Events beschrieben. Hierzu werden die Sprachkonstrukte **‘gefolgt von’** und **‘gefolgt nach [‘Dauer von EventTacet‘] von’** eingeführt.

Zusammenfassung von ähnlichen Sequences zu TemporalPatterns

Im letzten Schritt der TWK werden ähnliche Sequences zu TemporalPatterns zusammengefaßt. *TemporalPatterns* sind Alternativen zwischen ähnlichen Sequences und besitzen eine minimale und eine maximale Dauer. Jedem TemporalPattern wird ein Name gegeben.

Zur Erkennung von ähnlichen Sequences können z.B. Stringaustauschalgorithmen eingesetzt werden [Ultsch 87]. Dabei werden Events als Zeichen dargestellt, wobei Sequences Substrings in einem String entsprechen. Durch Stringaustauschalgorithmen können ähnliche Sequences identifiziert und zu TemporalPatterns zusammengefaßt werden.

Generierung von TG-Regeln für TemporalPatterns

Für jedes TemporalPattern wird aus den bisherigen Zwischenergebnissen der TWK eine TG-Regel erzeugt, durch die Alternativen von Sequences in einem TemporalPattern Form einer symbolischen Wissensrepräsentation beschrieben werden. Hierzu wird das Sprachkonstrukt **‘oder’** eingeführt.

3.3 Schritte der TWK

In diesem Kapitel werden die algorithmischen Schritte der TWK (s. Abb.13, S. 49) beschrieben. Hierbei sind die auf den verschiedenen Abstraktionsebenen der TWK erzeugten Zwischenergebnisse Grundbausteine für eine temporale Grammatik (TG).

3.3.1 Vorverarbeitung und Merkmalsextraktion

Im folgenden werden die Schritte zur Vorverarbeitung und Merkmalsextraktion für multivariate Zeitreihen vorgestellt. Es ist wesentliches Ziel einer Merkmalsextraktion, Merkmale aus Zeitreihen zu extrahieren, so daß eine Überführung in eine für ein Problem geeignete Repräsentation erfolgen kann. Dabei werden häufig Verfahren aus Statistik, Signalverarbeitung und Fuzzy-Theorie eingesetzt. Die verschiedenen Verfahren sollen nicht vorgestellt werden, da für jede Anwendung andere Vorverarbeitungsstrategien erforderlich sind. Hingegen werden hier häufig auftretende Probleme bei der Vorverarbeitung von Zeitreihen dargestellt. Insbesondere werden mögliche Fehlerquellen bei der Verarbeitung von Zeitreihen aufgeführt.

Vor einer Merkmalsextraktion ist die Behebung aller in Zeitreihen auftretenden Fehler erforderlich. Fehlende und fehlerbehaftete Daten müssen durch geeignete Vorverarbeitungsstrategien bereinigt werden. Es handelt sich dabei vor allem um Fehler, die bei Abtastung von Signalen auftreten, z.B. durch Störungen bei der Signalaufnahme. Beispielsweise kann die Bewegung eines Patienten, bei dem mehrere Größen über eine Nacht aufgenommen werden, zu einer gestörten Aufnahme einer oder mehrerer Größen führen.

Liegt eine genügend große Datenmenge vor, so können die Zeitbereiche mit den fehlenden oder fehlerbehafteten Daten unberücksichtigt bleiben. Dabei ist zu beachten, daß eine Entfernung der Zeitbereiche mit fehlenden oder fehlerbehafteten Daten nicht zu einer Veränderung der ursprünglichen Verteilung der Daten führt.

Bei kleinen Datenmengen müssen fehlende Daten ergänzt bzw. fehlerbehaftete Daten ersetzt werden. Übliche Verfahren sind das Ergänzen der Daten durch deren Mittelwert oder Median bzw. die Durchführung einer Interpolation oder einer Regression anhand der vorhandenen Daten [Bishop 95]. Diese Verfahren liefern jedoch meist unbefriedigende Ergebnisse. Alternativ hierzu eignen sich zur Mu-

stervervollständigung z.B. selbstorganisierende Merkmalskarten oder Assoziativspeicher [Ultsch et al. 96, Schwenker et al. 95]. Andere Verfahren berücksichtigen die Varianz in den Daten. Hierbei wird von der Verteilung der Daten ausgegangen, wobei Zufallsvektoren aus der Verteilung generiert werden. Dadurch werden mehrere Ergänzungen desselben Musters vorgenommen [Bishop 95, Lowe/Webb 90].

Weiterhin liefert eine genaue Betrachtung der Zeitreihen anhand eines Plots Hinweise auf mögliche Fehlerquellen. Zusätzlich ist ein Plot auch eine Diskussionsgrundlage, anhand dessen wesentliche Eigenschaften der Zeitreihen durch einen Experten für die Anwendung beschrieben werden können. Diese Eigenschaften können als Vorwissen bei der Merkmalsextraktion eingesetzt werden.

Es ist Ziel einer Merkmalsextraktion, für die Anwendung relevante Merkmale aus multivariaten Zeitreihen zu extrahieren. Das bedeutet, daß durch die Bestimmung von Merkmalen Zeitreihen in eine neue Repräsentationsform überführt werden. Dabei werden Zeitreihen auf wesentliche Merkmale reduziert. Werden Zeitreihen beispielsweise von verschiedenen Patienten aufgenommen, so treten hier wesentliche Unterschiede bei grundlegenden Eigenschaften wie z.B. Grundfrequenz, Offset, usw. der Zeitreihen auf. Durch eine geeignete Vorverarbeitung sollen diese Unterschiede behoben werden. Das heißt, daß durch eine Merkmalsextraktion Transformationen auf Zeitreihen derart durchgeführt werden, daß eine Strukturanalyse¹ erfolgen kann. Vorverarbeitung und Merkmalsextraktion sind daher wichtige Schritte für die Erkennung von TemporalPatterns, da sie alle weiteren Schritte der TWK beeinflussen (s. Abb. 13, S. 49). Eine Merkmalsextraktion, bei der anwendungsabhängige Kriterien berücksichtigt werden, kann erst dann erfolgen, wenn das Wissen eines Experten für die Anwendung über die Zeitreihen in die Merkmalsextraktion einfließt. In der Regel führt dies zu einer effektiveren Merkmalsextraktion, wobei die Vorverarbeitung als einer der wesentlichen Faktoren für die Gesamtleistung des Systems angesehen wird [Kohonen 95, Bishop 95]. Demnach ist eine problemabhängige Merkmalsextraktion automatischen Verfahren zur Vorverarbeitung vorzuziehen.

Verschiedene Verfahren können zur Vorverarbeitung und Merkmalsextraktion von Zeitreihen eingesetzt werden. Hier seien nur einige erwähnt. In der Statistik werden zur Merkmalsextraktion hauptsächlich Verfahren aus der Faktorenanalyse und Hauptkomponentenanalyse verwendet [Bishop 95, Fukunaga 90]. Verfahren

1. Zur Vorhersage von Zeitreihen wird die Vorverarbeitung nach anderen Kriterien durchgeführt. Hier ist Zielkriterium eine optimale Prognose, wobei ein für das Problem geeignetes statistisches Modell oder künstliche neuronale Netze verwendet wird [Schlittgen/Streitberg 94, Weigend/Gershenfeld 94].

aus der Signalverarbeitung, die zur Merkmalsextraktion eingesetzt werden können, sind das Powerspektrum, die Gabor-Transformation und Wavelets [Masters 93].

Außerdem ist eine Vorverarbeitung der extrahierten Merkmale für eine Strukturanalyse von Merkmalen erforderlich [Masters 93, Bishop 95, Ultsch 92]. Die Vorverarbeitung umfaßt im wesentlichen vier Teilziele (s. Kapitel 4.1): (1) die Angleichung der Verteilungen auf eine geeignete Normierung mit vergleichbaren Verteilungen z.B. auf Normalverteilung, (2) die Eliminierung von Ausreißern, (3) die Normierung aller Komponenten auf einen bestimmten Wertebereich z.B. durch eine Z-Transformation und (4) die Eliminierung korrelierter Komponenten der normierten Eingabevektoren. Durch die o.g. Transformationen werden die Merkmale vergleichbar gemacht. Dies ist für eine Strukturanalyse und damit für die Klassenbildung wesentlich.

Die hier vorgestellten Schritte zur Merkmalsextraktion führen zu einer neuen, dem Problem angepaßten Repräsentation von Zeitreihen mit folgenden Eigenschaften:

- Alle Fehler in den Zeitreihen sind beseitigt.
- Die Zeitreihen sind in eine für das Problem geeignete Repräsentation überführt.
- Die Zeitreihen sind auf wesentliche Merkmale reduziert.
- Anhand der Merkmale ist eine Strukturanalyse möglich.

3.3.2 Gewinnung von PrimitivePatterns durch eine Strukturanalyse

In diesem Schritt der TWK werden durch eine Strukturanalyse in einer Menge von ausgewählten Merkmalen (Selektion) aller möglichen Zeitpunkte ggf. Klassen identifiziert, die als PrimitivePattern-Klassen bezeichnet werden. PrimitivePattern-Klassen werden Namen gegeben. Kann eine Selektion von Merkmalen zu einem bestimmten Zeitpunkt t einer *PrimitivePattern-Klasse* mit Namen 'p' zugeordnet werden, so wird das als das Auftreten des *PrimitivePattern* mit Namen 'p' zum Zeitpunkt t betrachtet.

Selektionen von Merkmalen, die keiner PrimitivePattern-Klasse zugeordnet werden können, gehören einer besonderen Klasse an. Dieser Klasse wird der Name *Tacet* gegeben.

Die Auswahl von Merkmalen (Selektion) zur Strukturanalyse erfolgt durch anwendungsbezogene Kriterien, so daß Abhängigkeiten zwischen einzelne Zeitreihen getrennt untersucht werden können. Durch eine Strukturanalyse (s. Kapitel 2.1.2) wird jeder Selektion von Merkmalen ggf. eine PrimitivePattern-Klasse zugeordnet. Dabei sollen PrimitivePatterns, die zu einer PrimitivePattern-Klasse gehören, sich möglichst ähnlich sein. Verschiedene PrimitivePattern-Klassen sollen möglichst unterschiedliche PrimitivePatterns enthalten [Hartung 91].

Bei einer Strukturanalyse wird kein Vorwissen über Klassenzugehörigkeiten vorausgesetzt. Verfahren, bei denen die Klassen a priori nicht als bekannt vorausgesetzt werden, sind u.a. Verfahren zur Clusteranalyse und künstliche neuronale Netze mit unüberwachtem Lernverfahren.

Verfahren in der Statistik, die zur Strukturanalyse eingesetzt werden können, sind z.B. hierarchische Clusterverfahren [Bock 74, Hartung/Elpelt 84]. Bei hierarchischen Clusterverfahren werden Objekte auf jeweils unterschiedlichen Distanz- oder Ähnlichkeitsebenen gruppiert. Es wird eine stufenweise Verfeinerung (divisive Verfahren) oder Vergrößerung (agglomerative Verfahren) der Partitionen auf verschiedenen Ebenen vorgenommen. Der Nachteil dieser Verfahren liegt darin, daß die Anzahl der Klassen von der Auswahl einer Distanzebene abhängt.

Künstliche neuronale Netze mit unüberwachtem Lernverfahren, die zur Strukturanalyse eingesetzt werden können, sind die selbstorganisierenden Merkmalskarten (SOM) nach dem Modell von Kohonen (1984). Durch SOM werden bestimmte Eigenschaften (Nachbarschaften und Dichte) eines hochdimensionalen Raumes auf einem Raum mit einer wesentlich geringeren Dimensionalität (meist auf einer zweidimensionalen Neuronenschicht) so getreu wie möglich wiedergegeben [Kohonen 84]. Durch eine geeignete Visualisierung der angelernten Netzstruktur durch U-Matrizen wird eine Erkennung von Strukturen in mehrdimensionalen Daten möglich [Ultsch 92]. Dabei werden Bereiche auf einer U-Matrix, die in einem durch "Mauern" eingegrenzten "Tal" liegen, als eine Klasse aufgefaßt (s. Kapitel 2.1.2).

Werden U-Matrizen zur Erkennung von PrimitivePatterns eingesetzt, so entsprechen "Täler" auf einer U-Matrix ggf. PrimitivePattern-Klassen. PrimitivePattern-Klassen werden Namen gegeben. Eine Selektion von Merkmalen wird zu einem bestimmten Zeitpunkt t einem Bestmatch auf der U-Matrix zugeordnet. Liegt ein Bestmatch in einem "Tal", d. h. wird es einer PrimitivePattern-Klasse mit Namen 'p' zugeordnet, so entspricht dieser Bestmatch ein zum Zeitpunkt t auftretendes PrimitivePattern mit Namen 'p'. Alle anderen Bestmatches, die auf Bereiche der U-Matrix fallen, die keiner PrimitivePattern-Klasse zugeordnet worden sind, wer-

den der Klasse Tacet zugeordnet. Jede Selektion von Merkmalen wird dadurch einer PrimitivePattern-Klasse oder der Klasse Tacet zugeordnet.

Auf dieser Ebene findet ein erster semantischer Übergang in der temporalen Wissenskonversion statt. Durch diesen Schritt wird eine multivariate Zeitreihe in mehrere PrimitivePattern-Folgen überführt. PrimitivePatterns können dabei als primitive Muster in Zeitreihen auf elementarster Ebene aufgefaßt werden.

3.3.3 Erkennung von Successions

Eine *Succession* ist eine aus unmittelbar aufeinanderfolgenden Zeitpunkten bestehende Folge eines gleichen PrimitivePattern. Einer Succession wird der Name 's' gegeben, falls alle PrimitivePatterns einer Succession denselben Namen 's' besitzen. Könnte für PrimitivePatterns ein für die Anwendung bedeutsamer Name hergeleitet werden, so wird er auch den Successions zugeordnet. Eine Succession fängt zu einem Startzeitpunkt a an und endet zu einem Endzeitpunkt $e := a + l$. Im Gegensatz zu PrimitivePatterns besitzen daher Successions eine Dauer l . Eine aus unmittelbar aufeinanderfolgenden Zeitpunkten bestehende Folge von Tacets wird weiterhin als *Tacet* bezeichnet.

Eine Succession mit Namen 's' wird durch ihren Start- und Endzeitpunkt identifiziert. Der Startzeitpunkt a einer Succession 's' wird dadurch erkannt, daß zu einem Zeitpunkt a ein PrimitivePattern mit Namen 's' nach einem PrimitivePattern mit einem anderen Namen als dem Namen 's' oder einem Tacet in einer PrimitivePattern-Folge auftritt. Der Endzeitpunkt $a+l$ einer Succession 's' wird dadurch erkannt, daß nach einem Startzeitpunkt a l -mal unmittelbar aufeinanderfolgende gleiche PrimitivePatterns mit Namen 's' auftreten, und zum Zeitpunkt $a+l+1$ ein PrimitivePattern mit einem anderen Namen als dem Namen 's' oder ein Tacet auftritt. Durch den Startzeitpunkt a und den Endzeitpunkt $a+l$ wird die Dauer l einer Succession bestimmt.

Zur Erkennung von Successions mit Hilfe von U-Matrizen können Wege auf einer U-Matrix folgendermaßen betrachtet und interpretiert werden (s. a. Kapitel 4.3). Unmittelbar aufeinanderfolgende PrimitivePatterns, die Bestmatches auf einer U-Matrix entsprechen, werden durch Kanten miteinander verbunden. Verläuft ein solcher Weg innerhalb eines "Tals" auf einer U-Matrix, d.h. innerhalb derselben PrimitivePattern-Klasse, so werden die auf dem Weg vorkommenden PrimitivePatterns zu einer Succession zusammengefaßt. Ein Übergang zu einer anderen PrimitivePattern-Klasse über eine "Mauer" auf einer U-Matrix bedeutet, daß die

nächste Succession beginnt. Start und Ende einer Succession werden durch solche Übergänge festgestellt. Dabei kann ein Übergang direkt, d.h. der Übergang erfolgt direkt zur nächsten PrimitivePattern-Klasse über eine Mauer, oder über die Klasse Tacet erfolgen. Tacets sind Bereiche auf der U-Matrix, die keiner PrimitivePattern-Klasse zugeordnet worden sind.

Der letzte Schritt bei der Erkennung von Successions besteht darin, auftretende Störungen in Successions zu entfernen. Dabei werden sehr kurze Successions und sehr kurze Unterbrechungen in einer Succession ggf. als Störungen aufgefaßt. Dabei werden sehr kurze Successions anhand von Histogrammem identifiziert und in ein Tacet überführt. Sehr kurze Unterbrechungen in einer Succession mit Namen 's' werden dadurch erkannt, daß der prozentuale Anteil der Dauer der Unterbrechung sehr klein ist im Vergleich zur Gesamtdauer der Succession. Den PrimitivePatterns dieser sehr kurzen Unterbrechung wird der Name 's' der Succession gegeben. Eine sehr kurze Unterbrechung darf z.B. 15% der Gesamtdauer einer Succession nicht überschreiten.

3.3.4 Erkennung von Events durch ungefähr gleichzeitige Successions

Ungefähr gleichzeitig auftretende Successions werden als *Event* bezeichnet. Successions treten nur dann ungefähr gleichzeitig auf, wenn die Dauer des gleichzeitigen Auftretens der Successions bedeutend größer ist als deren Abweichungen vom gleichzeitigen Auftreten (s. Definition 3.1.4). Events, die aus denselben ungefähr gleichzeitig auftretenden Successions bestehen, jedoch zu unterschiedlichen Zeitpunkten auftreten, wird derselbe Name 'e' gegeben. Successions können auch mit Tacets gleichzeitig auftreten, wobei mindestens eine Succession in einem Event vorkommen muß. Treten ausschließlich Tacets ungefähr gleichzeitig auf, so werden sie als *EventTacet* bezeichnet.

Ein Event bzw. EventTacet besitzt eine Dauer l , die aus dem Startzeitpunkt A und dem Endzeitpunkt E des Events bzw. EventTacet bestimmt wird. Dabei wird der Startzeitpunkt bzw. Endzeitpunkt eines Events durch den Startzeitpunkt bzw. Endzeitpunkt des gleichzeitigen Auftretens aller im Event vorkommenden Successions bestimmt.

Da bestimmte Successions häufiger als andere ungefähr gleichzeitig auftreten können, kann ggf. zwischen sehr häufigen und weniger häufigen Events unterschieden werden. Zur Identifikation unterschiedlich häufiger Events wird die An-

zahl von gleichzeitig auftretenden PrimitivePatterns in den verschiedenen Events bestimmt. Dabei kann die Häufigkeit des gleichzeitigen Auftretens von PrimitivePatterns variieren. Anhand eines Histogramms kann ggf. zwischen sehr häufigen, weniger häufigen und seltenen Events unterschieden werden. Weniger häufige Events werden, falls möglich, den sehr häufigen Events zugeordnet. Hierzu kann z.B. die Anzahl übereinstimmender Merkmale in den sig*-Regeln für die PrimitivePatterns bestimmt werden.

Zur Erkennung von Events können hierarchische SOM eingesetzt werden (s. Kapitel 4.2). Hierarchische SOM sind zweischichtig aufgebaut, wobei mehrere SOM auf der ersten und eine SOM auf der zweiten Schicht vorhanden sind. Auf der ersten Schicht werden PrimitivePatterns mit Hilfe von U-Matrizen identifiziert. Durch eine geeignete Kodierung der PrimitivePatterns (Bestmatches) auf den U-Matrizen wird die Eingabe für die SOM der zweiten Schicht generiert (s. Abb.16, S. 78). Auf der zweiten Schicht werden Events mit Hilfe einer U-Matrix bestimmt. Dabei werden Bereiche auf der U-Matrix, die in einem durch "Mauern" eingegrenzten "Tal" liegen, als eine Klasse aufgefaßt. Jeder Klasse wird ein Name gegeben, die dem Namen der Events dieser Klasse entsprechen. Anhand der Größe der "Täler" kann zwischen unterschiedlich häufigen Events unterschieden werden. Sehr häufige Events verlaufen in großen "Tälern" auf einer U-Matrix. Um feststellen zu können, welche der weniger häufigen Events den sehr häufigen Events zugeordnet werden können, können z.B. Nachbarschaften zwischen den Events auf der U-Matrix betrachtet werden. Ähnliche Events liegen auf einer U-Matrix nahe beieinander und können ggf. zusammengefaßt werden.

Der letzte Schritt bei der Erkennung von Events besteht darin, auftretende Störungen zu entfernen. Sehr kurze Events werden dabei als nicht bedeutsame Ereignisse betrachtet. Sehr kurze Unterbrechungen in den Events werden als Störungen aufgefaßt und werden beseitigt. Dabei wird genauso wie bei den Successions vorgegangen (s. Kapitel 3.3.3).

Durch Events findet ein weiterer semantischer Übergang in der temporalen Wissenskonversion statt. Events beschreiben daher wesentliche Ereignisse in multivariaten Zeitreihen auf einer symbolischen Ebene.

3.3.5 Identifikation von Sequences in Eventfolgen

Sequences sind Teilfolgen in einer Eventfolge, die in der Eventfolge wiederholt auftreten. Das erste Event in einer Sequence wird als *Startevent* und das letzte Event als *Endevent* bezeichnet. Jeder Sequence wird ein Name gegeben.

Die Dauer eines Events mit Namen 'j' kann in derselben Sequence 's' zu verschiedenen Zeitpunkten verschieden sein. Daher besitzt jedes Event einer Sequence 's' eine minimale und eine maximale Dauer. Die minimale bzw. die maximale Dauer eines Events 'j' einer Sequence 's' wird durch das Minimum bzw. das Maximum der Dauer aller Events mit Namen 'j' der Sequence 's' bestimmt.

Die Dauer einer Sequence 's' zu einem bestimmten Zeitpunkt t entspricht der Summe über die Dauer aller in der Sequence auftretenden Events und EventTacets berechnet. Da eine Sequence 's' in einer Eventfolge wiederholt auftritt, besitzt sie eine minimale und eine maximale Dauer. Dies gilt für alle in einer Eventfolge vorkommenden Sequences.

Werden Events als eine Einheit aufgefaßt, so kann jedes Event als ein Zeichen dargestellt werden. Eventfolgen werden hierbei als Zeichenketten (Strings) dargestellt. Sequences sind dann Substrings in einem String.

Die Erkennung von Substrings in Strings ist ein bekanntes Problem der Informatik. Hier werden jedoch die zu identifizierenden Substrings in der Regel als bekannt vorausgesetzt [Aho 90]. Das Problem tritt auch bei der Strukturanalyse von DNA- und Proteinsequenzen auf, wobei in der Regel nach bekannten Substrings gesucht wird [Searls/Dong 93]. Diese Voraussetzungen sind bei der Erkennung von Sequences in Eventfolgen nicht gegeben, da die zu entdeckenden Muster unbekannt sind. Durch die o.g. Einschränkungen für komplexe Muster wird der Suchraum deutlich eingeschränkt.

Ein Hinweis für Sequences in einer Eventfolge können z. B. stochastische Automaten [Bukharaev 95] liefern. Die Zustände eines stochastischen Automaten entsprechen Events. Zustandsübergänge eines solchen Automaten entsprechen Übergängen zwischen Events, wobei Übergangshäufigkeiten angegeben werden. Zyklen in einem stochastischen Automaten liefern einen Hinweis auf Folgen von Events, die sich wiederholen, und damit auf Sequences.

Sequences werden in dieser Arbeit durch Startevents und Endevents identifiziert. Sequences können als Wörter einer Sprache aufgefaßt werden, die aus einer Folge von Zeichen, den Events, bestehen. Der Übergang von einem Wort zum nächsten

in der gesprochenen Sprache kann durch eine Pause erkannt werden. Das kann für Sequences so interpretiert werden, daß länger andauernde EventTacets zwischen zwei Events auf einen Übergang zwischen zwei Sequences hindeuten. Dies bedeutet, daß Startevents als Events nach einem länger andauernden EventTacet und Endevents als Events vor einem länger andauernden EventTacet erkannt werden können. Deutlich länger andauernde EventTacets können anhand eines Histogramms bestimmt werden. Events, die häufig nach bzw. vor einem länger andauernden EventTacet auftreten, werden als Startevents bzw. Endevents identifiziert. Durch die Erkennung von Startevents und Endevents kann eine Eventfolge, die einem String entspricht, in Substrings zerlegt werden. Die Substrings entsprechen dann den Sequences.

3.3.6 Zusammenfassung von ähnlichen Sequences zu TemporalPatterns

Die Erkennung von TemporalPatterns ist der letzte Schritt der TWK. Ähnliche Sequences werden hier zu einem TemporalPattern zusammengefaßt. *TemporalPatterns* sind dabei Alternativen zwischen ähnlichen Sequences und besitzen eine minimale und eine maximale Dauer. Jedem TemporalPattern wird ein Name gegeben.

Werden Events als Zeichen dargestellt, so entsprechen Sequences Substrings in einem String. Ähnliche Substrings können u.a. durch Stringaustauschalgorithmien festgestellt werden [Ultsch 87], die auf folgende Eigenschaften von Strings zurückgeführt werden: Zeichenmenge, Zeichenposition, gemeinsame Zeichenketten und Fehlerkategorien [Juon 85]. Dabei beziehen sich die Operationen u.a. auf die Position der Zeichen in einem String: Einfügen eines Zeichens, Entfernen eines Zeichens, Ersetzen eines Zeichens durch ein anderes Zeichen und Umkehrung zweier Zeichen in einem String. Zur Bestimmung von ähnlichen Substrings werden die o.g. Operationen auf Substrings angewendet und dadurch Distanzen zwischen Substrings berechnet. Diese werden für alle Substrings in eine Tabelle eingetragen. Anhand der Tabelle können ähnliche Substrings identifiziert werden (s. Kapitel 5.2.6).

3.4 Gewinnung von temporalen Grammatiken (TG)

Wesentliches Ziel dieser Arbeit ist die Überführung von multivariaten Zeitreihen in eine symbolische Darstellungsform. Dabei stellt sich das Problem, eine geeignete, für Menschen interpretierbare und kommunizierbare Darstellungsform zeitlicher Verläufe zu finden. Es existieren verschiedene Formalismen zur Repräsentation von Wissen, u.a. natürliche und formale Sprachen, Produktionssysteme, Konzeptrahmen (Frames), semantische Netze, Prädikatenlogik [Tanimoto 90]. Insbesondere ist Sprache, in welcher Form auch immer, die verbreitetste und natürlichste Darstellung für Wissen [Bibel et al. 93]. Da in dieser Arbeit die Verständlichkeit des aus multivariaten Zeitreihen gewonnenen Wissens im Vordergrund steht, wird hier eine sprachliche Darstellungsform in Form einer formalen Grammatik gewählt. Die Repräsentation in einer sprachlichen Form besitzt Vorteile bzgl. der Kommunikation, der Verständlichkeit und der Interpretation des nun sprachlich repräsentierten Wissens [Kurfess 95, Wermer 95].

Sprachen enthalten stets ein Vokabular und einen Satz grammatikalischer Regeln, wobei zwischen Syntax, Semantik und Pragmatik einer Sprache unterschieden wird [Schneider 91]. In der Informatik werden formale Sprachen durch Regelsysteme definiert, die in Analogie zu Regelsystemen natürlicher Sprachen Grammatiken genannt werden [Wegener 93]. Grammatiken wurden formal im Jahre 1956 durch den Linguisten Chomsky definiert und bestehen aus vier Komponenten:

- T (*Terminale*), einem endlichen Alphabet, über dem die zu erzeugende Sprache definiert ist,
- N (*Nichtterminale*), einer endlichen, zu T disjunkten Menge von Hilfszeichen,
- $S \in V$, dem *Startsymbol* und
- P , einer endlichen Menge von *Ableitungsregeln*.

Eine Ableitungsregel¹ ist ein Paar (l, r) (linke und rechte Seite einer Regel), wobei $l \in (V \cup T)^+$ und $r \in (V \cup T)^*$ ist. Wenn die linke Seite einer Ableitungsregel (l, r) Teilwort in einem Wort z ist, dann darf l durch r ersetzt werden. In der Informatik wird für Ableitungsregeln die Notation $l \rightarrow r$ verwendet.

1. Eine Ableitungsregel wird im folgenden auch als Regel bezeichnet.

Die von einer Grammatik G erzeugte *Sprache* $L(G)$ besteht aus allen Wörtern $w \in T^*$, die in endlich vielen Schritten aus S durch Anwendung von Ableitungsregeln aus P abgeleitet werden können. Durch eine Grammatik wird die Syntax einer Sprache beschrieben. Unter Syntaxanalyse wird die Ermittlung der Struktur der Wörter einer Sprache $L(G)$ durch die Regeln der Grammatik G verstanden. Durch Konstruktion eines Parsers kann eine Syntaxanalyse maschinell durchgeführt werden. Ein Parser ist ein Computerprogramm gesteuert durch eine Grammatik G , der für ein Wort $w \in L(G)$ überprüft, ob dieses durch die Grammatik G erzeugt werden kann [Aho et al. 86]. Durch einen Parser wird einem Wort $w \in L(G)$ eine durch die Grammatik G gegebene Strukturbeschreibung zugeordnet.

Von besonderem Interesse für die Informatik sind kontextfreie Grammatiken, da hier das sog. Wortproblem, d.h. für ein Wort $w \in T^*$ zu entscheiden, ob $w \in L(G)$, in polynomieller Rechenzeit gelöst werden kann [Wegener 93]. Das bedeutet, daß für kontextfreie Sprachen effiziente Parser konstruiert werden können [Aho et al. 86]. *Kontextfreie Grammatiken* sind Grammatiken, bei denen alle Ableitungsregeln die Form $A \rightarrow v$ mit $A \in V$ und $v \in (V \cup T)^*$ haben.

Die Beschreibung und die Erkennung von komplexen Mustern in multivariaten Zeitreihen durch Grammatiken setzt voraus, daß die zeitlichen Abhängigkeiten in komplexen Mustern, wie z.B. die zeitliche Abfolge von Events, grammatikalisch beschrieben werden können. Ziel ist es dabei, komplexe Muster in multivariaten Zeitreihen durch eine Grammatik derart zu beschreiben, daß diese in eine für einen Menschen verständliche und überprüfbare Repräsentation vorliegen. Nach einem Vorschlag von A. Ultsch eignen sich hierzu z.B. unifikationsbasierte Grammatiken (UBG) [Ultsch 96b]. Eine UBG zur Beschreibung von komplexen Mustern in multivariaten Zeitreihen in einer allgemeinen Form wurde in Guimarães/Ultsch (1997) vorgestellt. UBG sind eine Erweiterung von kontextfreien Grammatiken [Pereira/Warren 80]. Die Dauer der Events, Sequences und TemporalPatterns kann dabei in den Regeln als Nebenbedingung formuliert werden (s.u.).

Der wesentliche Unterschied zwischen kontextfreien Grammatiken und UBG besteht darin, daß Nichtterminale zusammengesetzte Terme der Form $f(t_1, \dots, t_k)$ sein können, wobei f ein Funktor und t_i Argumente sind. Dabei können Argumente Konstanten, Variablen und wiederum zusammengesetzte Terme sein. Bei der Anwendung einer Regel aus einer kontextfreien Grammatik wird die linke Seite der Regel durch die rechte Seite der Regel ersetzt. Da in einer UBG Nichttermina-

le aus zusammengesetzten Termen bestehen, findet hier nicht nur eine Ersetzung des Nichtterminals der linken Seite durch die rechte Seite der Regel statt, sondern werden die Terme, wenn möglich, durch *Unifikation* identisch gemacht [Abramson/Dahl 89]. Die Unifikation besteht darin, daß durch eine Substitution eine Belegung der Variablen in Termen derart gesucht wird, daß die Terme gleich gemacht werden können [Sterling/Shapiro 86]. Die Unifikation von Termen setzt eine Unifikationsstrategie voraus, die in der Praxis häufig durch einen Prolog-Interpreter realisiert wird, der auch die Funktion eines Parsers bei der Syntaxanalyse übernimmt [Pereira/Schieber 87].

Die Regeln einer UBG können durch Bedingungen bzw. Tests erweitert werden [Abramson/Dahl 89]. Z.B. können in den Bedingungen Überprüfungen oder Berechnungen auf Variablen in Termen durchgeführt werden. Die Bedingungen werden üblicherweise am Ende einer Regel in geschweifte Klammern gestellt. Anhand eines Beispiels zur Bestimmung des Wertes einer Zahl mit drei Ziffern werden im folgenden solche Bedingungen erläutert.

Beispiel:

```

zahl(N) → ziffer(Z) hundert ziffer(Z1), {N := Z*100+Z1}
ziffer (1) → ein | eins
ziffer (2) → zwei
...

```

Diese Regel besagt, daß eine dreistellige Zahl N aus einer Ziffer mit Wert Z besteht, gefolgt von dem Wort *hundert*, und daß der Rest der Zahl mit Wert Z1 folgen muß. Durch die Bedingung wird festgelegt, daß der Wert der Zahl N durch eine Multiplikation von Z mit 100 und der Addition von Z1 berechnet wird. Bei Eingabe des Wortes ‘*zwei hundert eins*’ erfolgt durch Anwendung der Regel ‘zahl(N) → ziffer(Z) hundert ziffer(Z1), {N := Z*100+Z1}’ die Substitution Z = 2, Z1 = 1. Daraus folgt N = 2*100+1 = 201.

Im folgenden werden die einzelnen Schritte zur Generierung einer UBG mit Hilfe der TWK beschrieben, die in dieser Arbeit als temporale Grammatik (TG) bezeichnet wird. Die Regeln einer solchen Grammatik werden als TG-Regeln bezeichnet. Zur Generierung einer TG werden die Zwischenergebnisse der TWK auf den verschiedenen Abstraktionsebenen als Grundbausteine für die Konstruktion von TG-Regeln verwendet (s. Abb.14). Es werden TG-Regeln für Temporal-Patterns, Sequences und Events erzeugt. Da in dieser Arbeit die Verständlichkeit einer solchen Regel im Vordergrund steht, z.B. für die Interpretation der Regeln in einem Expertengespräch, so wird im folgenden anstatt → das Sprachkonstrukt

‘falls’ verwendet. Zur Beschreibung von zeitlichen Abhängigkeiten in TG-Regeln werden spezielle Sprachkonstrukte eingeführt. Es handelt sich dabei um die Sprachkonstrukte ‘**gefolgt von**’, ‘**gefolgt nach** [‘Dauer’] **von**’, ‘**ist ungefähr gleichzeitig mit**’ und ‘**oder**’. Diese Sprachkonstrukte sind Terminale der TG. Weitere Terminale sind die Namen der Successions. Die Namen der Events, die aus den Namen der Successions hergeleitet werden, werden als Namen für die Funktoren der Terme für die Events verwendet. Die durch die TWK bestimmte Dauer der TemporalPatterns, Events, usw. sind Variablen in Termen, die unifiziert und deren Wertebereiche durch Bedingungen überprüft werden können. Da im Rahmen dieser Arbeit die Verständlichkeit und Lesbarkeit der TG-Regeln für einen Menschen im Vordergrund steht, wird eine eigene Notation für TG-Regeln eingeführt. Dabei werden anstatt Variablen für die Dauer von TemporalPatterns, Events, usw. und deren Überprüfung durch Bedingungen Wertebereiche für die Dauer in eckigen Klammer angegeben. Zum Beispiel wird der Term *hypopnoe* (Dauer_von_hypopnoe) mit der Bedingung $\{Dauer_von_hypopnoe \geq 30 \text{ sec}, Dauer_von_hypopnoe \leq 45 \text{ sec}\}$ durch den Term *Hypopnoe* [30 sec, 45 sec] ersetzt, da sich dadurch die Lesbarkeit und Verständlichkeit der TG-Regeln verbessert. Eine Überführung in die ursprüngliche Notation ist dann einfach.

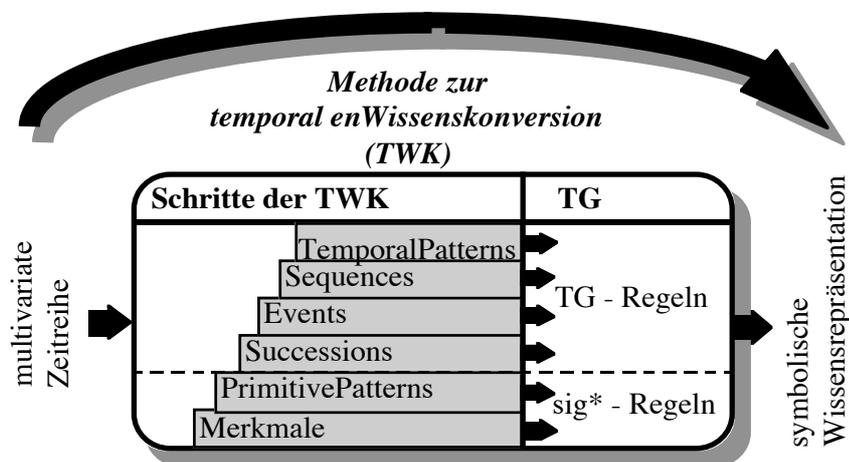


Abb.14: Methode zur temporalen Wissenskonversion (TWK) im Überblick

Generierung von TG-Regeln für TemporalPatterns

Die TWK liefert für jedes TemporalPattern:

- einen Namen und die minimale und die maximale Dauer des TemporalPatterns sowie
- Namen für die Sequences des TemporalPatterns und die minimale und maximale Dauer der Sequences

Schritte bei der Erzeugung der TG-Regel:

1. Schritt: Erzeuge die linke Seite der TG-Regel, indem ein Term mit dem Namen des TemporalPatterns und der minimalen und der maximalen Dauer des TemporalPatterns generiert wird.
2. Schritt: Erzeuge die rechte Seite der TG-Regel, indem für alle Sequences Terme mit den Namen der Sequences und der minimalen und der maximalen Dauer der Sequences generiert werden. Durch das Sprachkonstrukt ‘**oder**’ werden Alternativen zwischen Sequences beschrieben.

Beispiel:

Ein TemporalPattern ist eine

obstruktive Hypopnoe [18 sec, 37 sec]

falls

obstruktive Hypopnoe TypA [36 sec, 37 sec]

oder

obstruktive Hypopnoe TypB [18 sec, 35 sec]

In dem Beispiel steht auf der linken Seite der Regel ein Term bestehend aus einem Namen des TemporalPatterns *obstruktive Hypopnoe* und der minimalen und der maximalen Dauer des TemporalPatterns von [18 sec, 37 sec]. Auf der rechten Seite stehen Alternativen von Termen für die Sequences, die durch das Sprachkonstrukt ‘**oder**’ beschrieben werden. Die Terme für die Sequences bestehen aus den Namen der Sequences und der minimalen und der maximalen Dauer der Sequences. Z.B. bedeutet der Term *obstruktive Hypopnoe TypA* [36 sec, 37 sec], daß die Sequence mit dem Namen *obstruktive Hypopnoe TypA* eine minimale und eine maximale Dauer von [36 sec, 37 sec] besitzt.

Generierung von TG-Regeln für Sequences

Die TWK liefert für jede Sequence:

- die Folge der Events in der Sequence
- Angaben über das eventuelle Auftreten von EventTacets zwischen den Events
- einen für die Anwendung u.U. bedeutsamen Namen für die Events
- die minimale und maximale Dauer von Events und EventTacets in der Sequence

1. Schritt: Erzeuge die linke Seite der TG-Regel, indem ein Term mit dem Namen der Sequence und der minimalen und der maximalen Dauer der Sequence generiert wird.
2. Schritt: Erzeuge die rechte Seite der TG-Regel, indem für alle Events der Sequence Terme mit den Namen der Events und der minimalen und der maximalen Dauer der Events generiert werden. Direkt aufeinanderfolgende Events werden durch das Sprachkonstrukt '**gefolgt von**' beschrieben. Aufeinanderfolgende Events, zwischen denen ein EventTacet auftritt, werden durch das Sprachkonstrukt '**gefolgt nach** [*Dauer des EventTacets*]' **von**' beschrieben.

Beispiel:

Eine Sequence ist eine

obstruktive Hypopnoe TypA [36 sec, 37 sec]

falls

Event6: kein bis reduziertes Atemvolumen und gegenläufige Thorax und Abdomenbewegungen ohne Schnarchgeräusche [20 sec, 25 sec]

gefolgt nach [0 sec, 4 sec] **von**

Event5: großes Atemvolumen mit starken Thorax- und Abdomenbewegungen [11 sec, 15 sec]

In dem Beispiel steht auf der linken Seite der Regel ein Term bestehend aus dem Namen der Sequence *obstruktive Hypopnoe TypA* und der minimalen und der maximalen Dauer der Sequence von [36 sec, 37 sec]. Auf der rechten Seite der Regel stehen Terme für aufeinanderfolgende Events, die durch das Sprachkonstrukt ‘**gefolgt nach** [‘Dauer des EventTacets’] **nach**’ beschrieben werden. Die Events folgen nach einem EventTacet mit einer minimalen und einer maximalen Dauer von [0 sec, 4 sec] aufeinander. Events sind Terme bestehend aus dem Namen des Events und der minimalen und der maximalen Dauer des Events. Z.B. bedeutet der Term *Event5: großes Atemvolumen mit starken Thorax- und Abdomenbewegungen* [11 sec, 15 sec], daß das Event mit dem Namen *Event5: großes Atemvolumen mit starken Thorax- und Abdomenbewegungen* eine minimale und eine maximale Dauer von [11 sec, 15 sec] besitzt. Auf dieser Ebene soll zusätzlich durch eine Bedingung die Gesamtdauer der Sequence überprüft werden.

Generierung von TG-Regeln für Events

Die TWK liefert für jedes Event:

- die Successions, die ungefähr gleichzeitig auftreten,
- einen für die Anwendung bedeutsamen Name des Events und
- für die Anwendung bedeutsame Namen der Successions.

1. Schritt: Erzeuge die linke Seite der TG-Regel, indem ein Term mit dem Namen des Events generiert wird.
2. Schritt: Erzeuge die rechte Seite der TG-Regel, indem ungefähr gleichzeitig auftretende Alternativen von Successions durch das Sprachkonstrukt ‘**ungefähr gleichzeitig**’ beschrieben werden. Alternativen von Successions werden durch das Sprachkonstrukt ‘**oder**’ beschrieben.

Beispiel:

Ein Event ist ein

event5: großes Atemvolumen mit starken Thorax- und Abdomenbewegungen

falls

(*großes Atemvolumen mit Schnarchgeräuschen*
oder
reduziertes Atemvolumen mit Schnarchgeräuschen)

ist ungefähr gleichzeitig mit

starken Thorax- und Abdomenbewegungen

In dem Beispiel steht auf der linken Seite der Regel für das Event ein Term mit dem Namen des Events *Event5: großes Atemvolumen mit starken Thorax- und Abdomenbewegungen*. Auf der rechten Seite werden Alternativen von Successions, die ungefähr gleichzeitig auftreten, durch das Sprachkonstrukt ‘**ist ungefähr gleichzeitig mit**’ beschrieben. Dabei tritt eine Alternative der Successions *großes Atemvolumen mit Schnarchgeräuschen* und *reduziertes Atemvolumen mit Schnarchgeräuschen* ungefähr gleichzeitig mit *starken Thorax- und Abdomenbewegungen* auf.

Die Vorteile einer symbolischen Wissensrepräsentation für komplexe Muster in multivariaten Zeitreihen durch TG-Regeln sind vielfältig. Zunächst einmal sind TG-Regeln eine Grundlage für ein Gespräch mit einem Experten für die Anwendung. Indem für PrimitivePatterns u.U. bedeutungsvolle Namen aus den sig*-Regeln hergeleitet werden, und diese anschließend zur Namensgebung von Successions und Events eingesetzt werden, wird durch die TG-Regeln eine inhaltliche Beschreibung von temporalen Mustern in einer sprachlichen Form erreicht. Durch eine Expertenbefragung können somit die durch die TWK erzielten Zwischenergebnisse auf einer symbolischen Ebene interpretiert und überprüft werden (s. Kapitel 5.3.3).

Die Beschreibung von komplexen Mustern in multivariaten Zeitreihen auf einer symbolischen Ebene durch TG-Regeln bietet außerdem die Möglichkeit, auf dieser Ebene Änderungen bzw. Anpassungen der TG-Regeln vornehmen zu können. Zum Beispiel können die durch die TWK erzeugten Namen in TG-Regeln durch andere Namen aus der Anwendung ersetzt werden. Weiterhin sind Anpassungen von TG-Regeln an ein größeres oder neues Patientenkollektiv z.B. durch Veränderung der Intervalle für die Dauer oder z.B. durch Einfügen eines bisher nicht be-

rücksichtigten Events in einer Sequence möglich. Auf dieser Ebene kann eine TG für neue, bisher nicht aufgetretene komplexe Muster durch Hinzufügen weiterer TG-Regeln erweitert werden.

Ist eine Änderung bzw. Anpassung von TG-Regeln auf dieser symbolischen Ebene nicht möglich, so kann u.U. anhand von TG-Regeln festgestellt werden, auf welcher Ebene der TWK eine Optimierung der Zwischenergebnisse möglich ist. Hierzu wird die Ebene identifiziert, bei der Inkonsistenzen zwischen TG-Regeln und dem Expertenwissen aufgetreten sind. Es kann sich dabei z.B. um die Merkmalsextraktion, um die Klassifikation der PrimitivePatterns, usw. handeln (s. Abb.13, S. 49). Werden auf einer Ebene Änderungen vorgenommen, so müssen die verbleibenden Schritte der TWK bis zu den TemporalPatterns wiederholt werden. Aus den neuen Zwischenergebnissen der TWK wird nachträglich eine TG erzeugt werden, so daß ein Vergleich zwischen beiden Grammatiken auf einer symbolischen Ebene möglich ist.

Kapitel 4

Selbstorganisierende Merkmalskarten zur temporalen Wissenskonversion

In diesem Kapitel wird der Einsatz von selbstorganisierenden Merkmalskarten (SOM) zur temporalen Wissenskonversion aufgezeigt. SOM eignen sich zur temporalen Wissenskonversion, da sie im Zusammenhang mit der U-Matrix-Methode zur Strukturanalyse eingesetzt werden können. Um die Zwischenergebnisse auf den verschiedenen Ebenen der TWK zu erzeugen, sind hierarchische SOM erforderlich. Zur Erkennung von Strukturen in Zeitreihen werden U-Matrizen auf den verschiedenen Ebenen einer hierarchischen SOM eingesetzt. Zeitliche Verläufe können durch Wege auf U-Matrizen, die sich auf verschiedenen Ebenen befinden, beobachtet und interpretiert werden.

In Kapitel 4.1 werden verschiedene Ansätze zur Automatisierung der Vorverarbeitung durch SOM vorgestellt. Der Einsatz von U-Matrizen zur Erkennung von PrimitivePatterns und Events wird in Kapitel 4.2 dargestellt. Zur Erkennung von Events sind hierarchische SOM erforderlich. Der Einsatz von hierarchischen SOM erfordert eine geeignete Kodierung der Bestmatches auf den U-Matrizen der ersten Ebene, so daß diese als Eingabevektoren für die SOM auf der zweiten Ebene eingesetzt werden können. In Kapitel 4.3 werden Möglichkeiten zur Darstellung von zeitlichen Verläufen auf SOM vorgestellt. Außerdem wird hier dargestellt, wie Successions, Events und TemporalPatterns durch Wege auf U-Matrizen beobachtet und interpretiert werden können.

4.1 Vorverarbeitung mit Selbstorganisierenden Merkmalskarten

Der Einsatz von SOM zur Strukturanalyse erfordert in der Regel eine geeignete Vorverarbeitung der Daten. Dabei werden die Werte (Skalen) der verschiedenen Komponenten der Eingabevektoren vergleichbar gemacht [Ultsch 91]. Es werden hierbei vier Teilziele angestrebt:

1. Durch eine Angleichung der Verteilungen auf eine geeignete Normierung mit ähnlichen Skalen wie z.B. die Normalverteilung werden die verschiedenen Komponenten eines Eingabevektors vergleichbar gemacht.
2. Die Eliminierung von Ausreißern ist erforderlich, da ansonsten sich die Merkmalskarte nach den Ausreißern "ausrichtet" und dadurch Strukturen in den Daten durch die U-Matrix-Methoden nur unzureichend erkannt werden können.
3. Eine Normierung aller Komponenten auf einen vergleichbaren Wertebereich wird z.B. durch eine Z-Transformation durchgeführt, falls sich die Wertebereiche der Komponenten unterscheiden. Ansonsten dominieren Komponenten mit relativ hohen Werten beim Lernen.
4. Korrelierte Komponenten normierter Eingabevektoren werden eliminiert, damit bei einer Strukturanalyse durch SOM die korrelierten Komponenten nicht doppelt gewichtet werden.

Im folgenden werden zwei Ansätze zur Automatisierung der o.g. Vorverarbeitung durch SOM vorgestellt.

Ausreißer können durch eine geeignete Visualisierung von SOM durch U-Matrizen leicht identifiziert werden. Es bilden sich beim Lernen sog. "Töpfe" um die Bestmatches auf U-Matrizen aus, d.h. einzelne Bestmatches werden durch hohe "Mauern" auf einer U-Matrix umgeben. Diese können in einem ausgelernten Netz identifiziert und ggf. aus dem Datensatz entfernt werden.

In Ultsch/Halmanns (1991) wird vorgeschlagen, SOM zur Transformation von Komponenten in eine Normalverteilung oder symmetrische Verteilung einzusetzen. Die Bestimmung einer geeigneten Transformation erfolgt in der Regel durch einen "try and error" Prozeß, der hier durch den Einsatz von SOM automatisiert wird. Um vorliegende Verteilungen beurteilen zu können, müssen empirische Größen, wie Quantile, Perzentile, Schiefe usw. bestimmt werden. Es handelt sich dabei um Transformationen zur Überführung einer Komponente in eine Normal-

verteilung von der Form x^p . Dabei wird p als der sog. "ladder of power" bezeichnet, der die Eigenschaften der Transformationen kennzeichnet. Ein Schnellverfahren zur Suche der Transformation benutzt einen p-Quantilkoeffizienten der Schiefe der Verteilung und liefert mit Werten gegen Null den optimalen Exponenten. Zur Vorhersage des p-Quantilkoeffizienten wird der Kohonen-Algorithmus modifiziert, indem die zur vorhersagende Komponente mit angelernt wird. Diese wird jedoch nicht zur Bestimmung des Bestmatches verwendet. Eine Vorhersage des p-Quantilkoeffizienten eines neuen Eingabevektors ist nun möglich. Dabei wird der Bestmatch anhand der anderen statistischen Größen bestimmt und die zu vorhersagende Komponente mit dem p-Quantilkoeffizienten aus der Merkmalskarte ergänzt.

Der Einsatz von KNN zur Analyse von Signalen erfordert häufig eine spezielle Vorverarbeitung der Daten, die für die Güte des Gesamtsystems von besonderer Bedeutung ist [Niemann 90, Bishop 95, Kohonen 95]. Üblicherweise wird eine Merkmalsextraktion durchgeführt, bei der die Eigenschaften der Daten sowie die durch die Anwendung an die Merkmalsextraktion gestellten Anforderungen berücksichtigt werden. [Kohonen 95, Kaski 97]. Bei der Merkmalsextraktion wird die Überführung der Daten in eine für das Problem geeignete Repräsentation angestrebt. Dabei werden Merkmale extrahiert, die invariant gegenüber elementaren Transformationen der Daten sein sollten. In Kohonen (1995) wird hierzu ein erweitertes Modell der SOM vorgeschlagen, die sog. ASSOM (Adaptive-Subspace SOM). Ist jedoch Wissen aus der Anwendung über die Daten vorhanden, so sollte es in den Prozeß der Merkmalsextraktion eingebunden werden [Kaski 97, Kohonen 95]. In Cheng et al. (1994) wird daher eine interaktive Merkmalsextraktion zusammen mit einem Experten für die Anwendung vorgeschlagen.

Die Automatisierung der Vorverarbeitung ist für komplexe Probleme sehr schwierig und wird deshalb als ein selbständiger Forschungsgegenstand angesehen, der im Rahmen dieser Arbeit nicht behandelt werden kann.

4.2 U-Matrizen zur Erkennung von PrimitivePatterns und Events

Ein interessantes Einsatzgebiet von SOM ist die Untersuchung struktureller Eigenschaften mehrdimensionaler Daten [Ultsch 92, Kohonen 95, Kaski 97]. Durch eine geeignete Visualisierung der Gewichte durch eine der U-Matrix-Methoden können Strukturen in mehrdimensionalen Daten erkannt werden [Ultsch 92].

Der Einsatz von U-Matrizen im Rahmen der temporalen Wissenskonversion erfolgt nur dann, wenn Strukturen in mehrdimensionalen Daten gesucht werden, was bei der Erkennung von *PrimitivePatterns* der Fall ist, und wobei eine multivariate Merkmalsfolge vorausgesetzt wird. Aus einer multivariaten Merkmalsfolge werden mehrere Selektionen von Merkmalen bestimmt. Für die verschiedenen Selektionen von Merkmalen werden SOM angelernet. Durch eine der U-Matrix-Methoden werden U-Matrizen generiert, die zur Strukturanalyse eingesetzt werden.

Bei einer Strukturanalyse werden in der Regel die zeitlichen Abhängigkeiten zwischen den Merkmalen einer Selektion nicht berücksichtigt. Dabei wird jedes Merkmal unabhängig vom zeitlichen Kontext in einer beliebigen Reihenfolge als Eingabevektor zum Anlernen der SOM verwendet. Nach dem Lernen werden anhand einer U-Matrix Klassen bestimmt. Diese Bereiche auf den U-Matrizen entsprechen *PrimitivePattern*-Klassen. Alle anderen Bereiche auf der U-Matrix werden der Klasse *Tacet* zugeordnet. Dies bedeutet, daß jede Selektion von Merkmalen einer *PrimitivePattern*-Klasse oder der Klasse *Tacet* zugeordnet wird. Eine *PrimitivePattern*-Folge besteht aus einer zeitliche Abfolge von *PrimitivePatterns* und *Tacets*. Werden Strukturanalysen auf verschiedenen Selektionen von Merkmalsfolgen durchgeführt, so entsteht eine multivariate *PrimitivePattern*-Folge. Jede der *PrimitivePattern*-Folgen aus einer multivariaten *PrimitivePattern*-Folge wird auf jeweils einer U-Matrix dargestellt (s. Abb.15).

U-Matrizen können außerdem zur Erkennung von *Events* eingesetzt werden. Ziel ist es hier, ungefähr gleichzeitige Successions zu erkennen. Ungefähr gleichzeitige Successions sind so definiert, daß sie hauptsächlich gleichzeitig auftreten (s. Definition 3.1.6). Es dürfen dabei nur sehr kleine Abweichungen auftreten. Events können daher durch das gleichzeitige Auftreten von Successions in einer multivariaten *PrimitivePattern*-Folge erkannt werden. Das bedeutet, daß Strukturen in gleichzeitig auftretenden *PrimitivePatterns* gesucht werden.

Die Erkennung von Events ist erst durch den Einsatz von hierarchischen SOM möglich. Werden hierarchische SOM zur temporalen Wissenskonversion eingesetzt, so existieren mehrere SOM auf der ersten Ebene und eine SOM auf der zweiten Ebene einer hierarchischen SOM. Auf der ersten Ebene werden U-Matrizen zur Bestimmung von PrimitivePatterns eingesetzt. Events werden durch eine U-Matrix auf der zweiten Schicht erkannt (s. Abb.15).

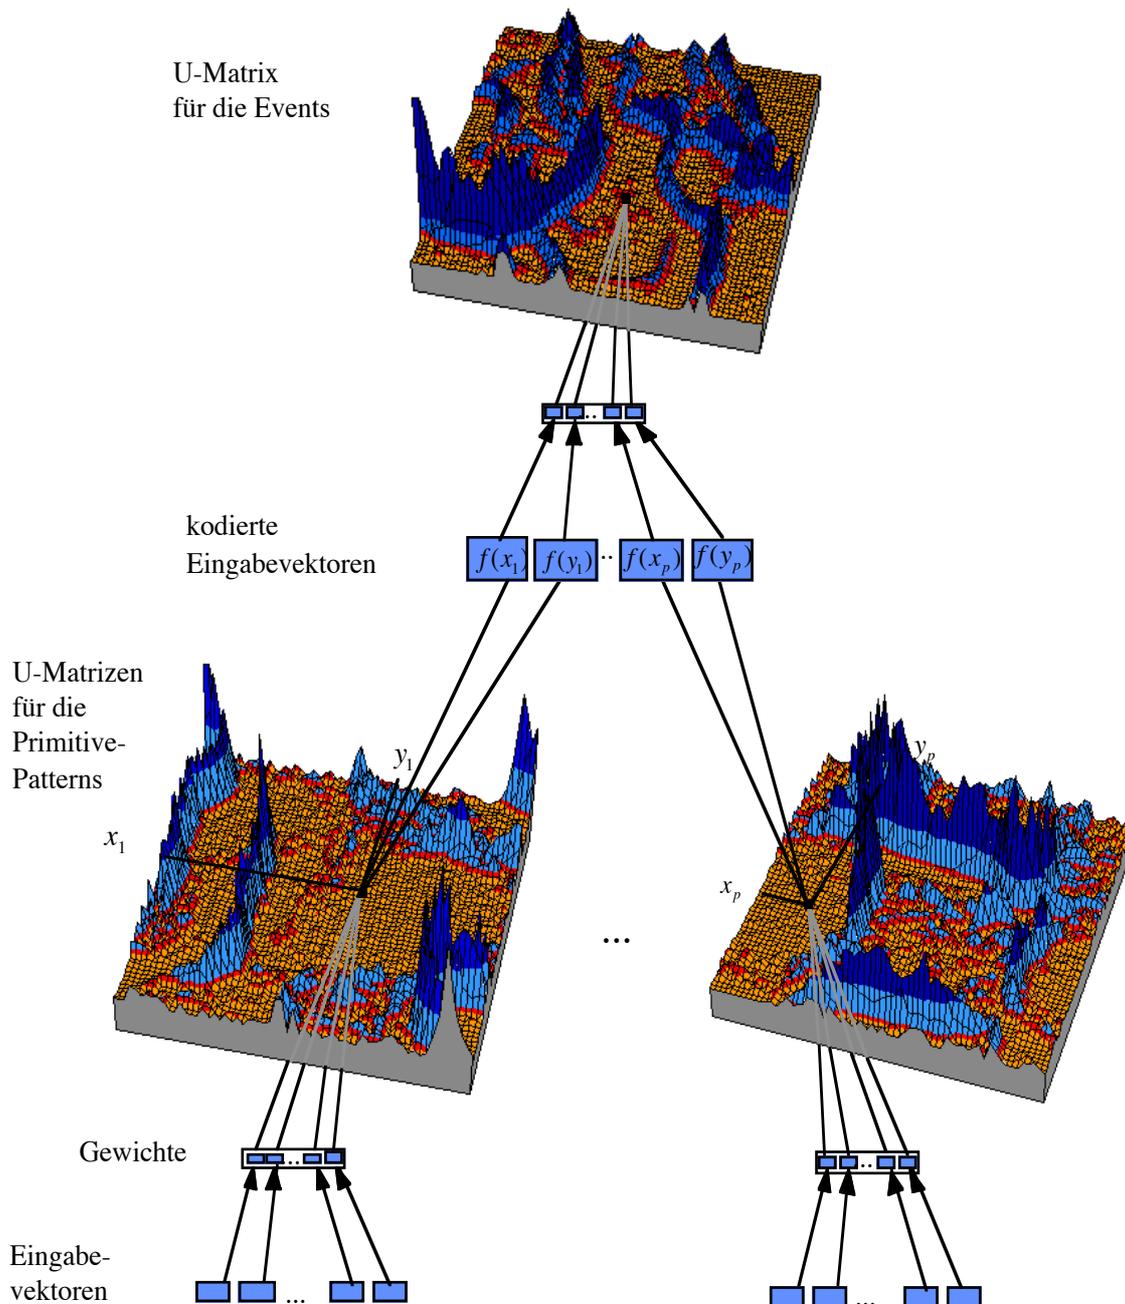


Abb.15: Hierarchische SOM mit U-Matrizen

Bisherige Ansätze "hierarchischer" SOM liegen im Bereich der Sprachverarbeitung [Kemke/Wichert 93] und der Bildverarbeitung [Koh et al. 95]. Beiden Ansätzen liegt zugrunde, daß das Problem in Teilprobleme zerlegt werden muß, so daß für jedes der Teilprobleme getrennt SOM angelernt werden. Das wesentliche Problem bei dem Einsatz von hierarchischen SOM liegt darin, eine geeignete Kodierung der ausgelerten Netzstrukturen der verschiedenen SOM der unteren Ebene als Eingabe für die SOM der oberen Ebene zu finden. Im Rahmen dieser Arbeit wird eine Kodierung für die Eingabevektoren der SOM der oberen Schicht vorgeschlagen, die die durch eine U-Matrix entdeckten Strukturen berücksichtigt. Dabei wird für alle Bestmatches auf einer Merkmalskarte, die in eine Klasse (PrimitivePattern-Klasse) fallen, der Klassenmittelpunkt berechnet. Die Position eines Bestmatches auf der Merkmalskarte wird dann durch den Abstand des Bestmatches auf der Merkmalskarte zu seinem Klassenmittelpunkt gewichtet. Bestmatches, die vom Klassenmittelpunkt weiter entfernt liegen, werden dadurch näher an den Klassenmittelpunkt herangezogen, als Bestmatches, die näher zum Klassenmittelpunkt liegen (s. Abb.16). Dadurch befinden sich alle Bestmatches auf der Merkmalskarte um ihren Klassenmittelpunkt. Die transformierten Koordinaten der Bestmatches auf den verschiedenen Merkmalskarten der ersten Ebene sind Eingabe für die SOM der zweiten Ebene. Bei einer solchen Kodierung wird sowohl die Klassifikation durch die U-Matrix als auch die Position der Bestmatches auf der Merkmalskarte berücksichtigt.

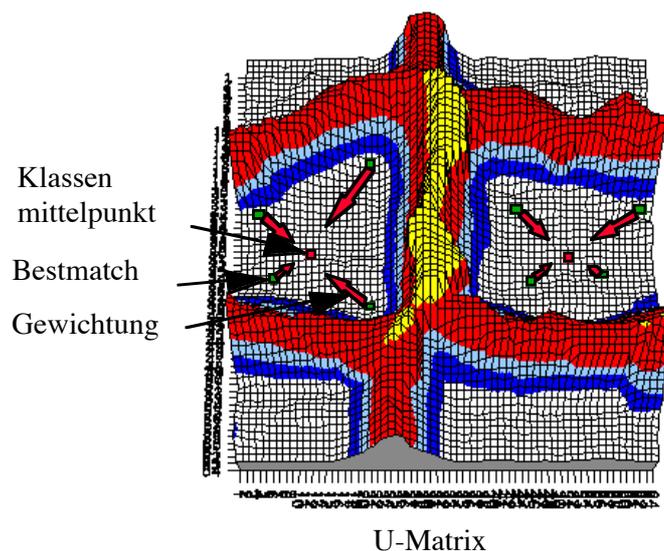


Abb.16: Kodierung der Eingabevektoren

Auf dieser Abstraktionsebene wird zwischen unterschiedlich häufig auftretenden Events differenziert. Diese Unterscheidung ist für die Erkennung von Events notwendig (s. Kapitel 3.3.4). Sollen unterschiedlich häufige Events durch eine U-Matrix identifiziert werden, so kann anhand der Ausdehnung eines "Tals" auf einer U-Matrix zwischen unterschiedlich häufig auftretenden Events unterschieden werden. Große "Täler" auf einer U-Matrix enthalten häufiger auftretende Events, kleine "Täler" dagegen weniger häufig auftretende Events. In einem nächsten Schritt sollen weniger häufig auftretende Events den sehr häufig auftretenden Events zugeordnet werden. Hinweise hierfür liefern z.B. Nachbarschaften von Events auf einer U-Matrix. Zusätzlich können hierzu die für die Events erzeugten TG-Regeln verwendet werden.

4.3 Wege auf U-Matrizen zur Visualisierung von Successions und TemporalPatterns

Zur Beobachtung und Interpretation von Prozessen, die aus einer zeitlichen Abfolge von Prozeßzuständen bestehen, werden häufig Wege auf SOM betrachtet [Ultsch 93]. Dabei entstehen Wege durch eine graphische Darstellung von zeitlich aufeinanderfolgenden Bestmatches auf einer SOM, indem die Bestmatches durch Kanten miteinander verbunden werden.

Die am häufigsten verwendete Darstellung von Wegen auf SOM ist diejenige, bei der die Wege direkt auf einer SOM ohne eine Visualisierung der angelegten Netzstrukturen betrachtet werden. Dieser Ansatz wird insbesondere in der Sprachverarbeitung und -erkennung eingesetzt [Kohonen 88, Kohonen 89, Behme et al. 93, Utela et al. 92, Leinonen et al. 93, Leinonen et al. 92, Hiltunen et al. 93, Mujunen et al. 93, Kita/Nishihawa 93, Tuya et al. 93]. Dabei werden Wörter als Wege auf einer Merkmalskarte interpretiert, wobei jeder Bestmatch einem Teil eines Wortes z.B. einem Phonem entspricht. Für diese Art von Problemen reicht eine solche Darstellung von Wegen aus, da eine Vorklassifikation bereits existiert. Ist eine Klassifikation vorgegeben, so können auf einer Merkmalskarte die Klassengrenzen "per Hand" "eingezeichnet" werden [Ritter/Kohonen 89]. Weiterhin wird dieser Ansatz im medizinischen Bereich eingesetzt. Harris (1993) schlägt vor, SOM zur Überwachung von medizinischen Geräten einzusetzen. Fehlzustände der Geräte sollen dabei vorhergesagt werden. Auch hier liegen Klassifikationen

durch die in der Vergangenheit aufgetretenen Fehlzustände von Prozessen vor. Ein weiteres Anwendungsgebiet in der Medizin ist die Visualisierung von EEG Signalen in Form von Wegen auf SOM [Joutsiniemi et al. 95, Kaski/Joutsiniemi 93]. In Principe/Wang (1995) wird vorgeschlagen, SOM zur Modellierung nicht-linearer Zeitreihen einzusetzen, wobei jedes Gewicht auf der Karte einer linearen lokalen Approximation an die Zeitreihe entspricht. Die Zeitreihe wird dann als Weg auf einer Merkmalskarte dargestellt. Letzendlich werden Wege direkt auf einer SOM auch im Bereich der Robotersteuerung verwendet, die zur Planung und Steuerung der Bewegungsabläufe von Robotern eingesetzt werden [Kröse/Eecen 94, Privitera/Morasso 93]. Auch hier ist der Soll-Zustand des Prozesses bekannt. Die Interpretation von Wegen auf SOM ist jedoch mit Schwierigkeiten verbunden, falls keine Information über die Klassenzugehörigkeit vorhanden ist. Daher werden zur Interpretation von Wegen auf SOM z.B. Heuristiken verwendet [Kohonen 88]. Andere Möglichkeiten zur Analyse von Wegen sind geeignete Visualisierungen der angelernten Netzstrukturen.

Komponentenkarten stellen eine Möglichkeit zur Visualisierung von SOM dar. Hierbei wird die Ausprägung einer Komponente auf der Merkmalskarte graphisch aufbereitet. Komponentenkarten werden beispielweise zur Prozeßüberwachung eingesetzt [Tryba/Goser 91, Kasslin et al. 92, Kohonen 95]. Das Monitoring von Zustandsänderungen eines Prozesses erfolgt dann durch Betrachtung von Wegen auf verschiedenen Komponentenkarten. Jede Komponente wird dabei getrennt betrachtet, wodurch der Einfluß jeder einzelnen Komponente auf den Prozeßzustand festgestellt werden kann. Schwierigkeiten bei der Interpretation von Komponentenkarten treten auf, falls die Anzahl der Komponenten groß ist. Bei einer großen Anzahl von Komponentenkarten geht schnell die Übersicht verloren. Dies erschwert die Interpretation von Prozeßzuständen bzw. Prozeßzustandsänderungen.

Im Gegensatz dazu besitzen U-Matrizen den Vorteil, daß alle Komponenten auf einer SOM gleichzeitig betrachtet werden und dadurch eine übersichtliche Darstellung des Prozeßverlaufes vorliegt. Durch eine U-Matrix kann außerdem eine Klassifikation der Prozeßzustände durchgeführt werden. In Ultsch (1993) wird vorgeschlagen, U-Matrizen zur Überwachung und Steuerung von chemischen Prozessen einzusetzen. Es wurden dabei Prozeßverläufe identifiziert, die in einen für den Prozeß kritischen Zustand gelangen.

Mit Hilfe einer U-Matrix können Klassen in hochdimensionalen entdeckt werden. Anhand einer U-Matrix ist jedoch Bedeutung der einzelnen Komponenten für eine Klasse nicht erkennbar. Dieser Nachteil kann durch die Gewinnung einer regelhaften Beschreibung der Klassen durch den Regelgenerierungsalgorithmus sig* [Ultsch 91] behoben werden.

Im Rahmen dieser Arbeit wird vorgeschlagen, multivariate Zeitreihen auf verschiedenen Abstraktionsebenen durch Wege auf U-Matrizen zu beobachten und zu erkennen (s. Abb.15, S. 77). Die U-Matrizen auf der ersten Ebenen einer hierarchischen SOM werden zur Bestimmung der PrimitivePatterns eingesetzt. Da Successions als unmittelbar aufeinanderfolgende PrimitivePatterns definiert sind, können Successions durch Wege auf einer U-Matrix erkannt werden (siehe Abb.17). Verläuft der Weg innerhalb eines "Tals", das einer PrimitivePattern-Klasse mit Namen 'j' zugeordnet wurde, so wird dieser Weg als eine Succession mit Namen 'j' identifiziert. Die Dauer einer Succession wird durch das Verbleiben des Weges in einem "Tal" bestimmt. Der Übergang von einer Succession zu nächsten erfolgt durch einen Übergang in ein nächstes "Tal" über eine "Mauer", das einer anderen PrimitivePattern-Klasse zugeordnet wurde. Der Übergang kann direkt erfolgen oder über Bereiche auf einer U-Matrix, die nicht als eine PrimitivePattern-Klasse identifiziert worden sind, sondern der Klasse Tacet zugeordnet wurden.

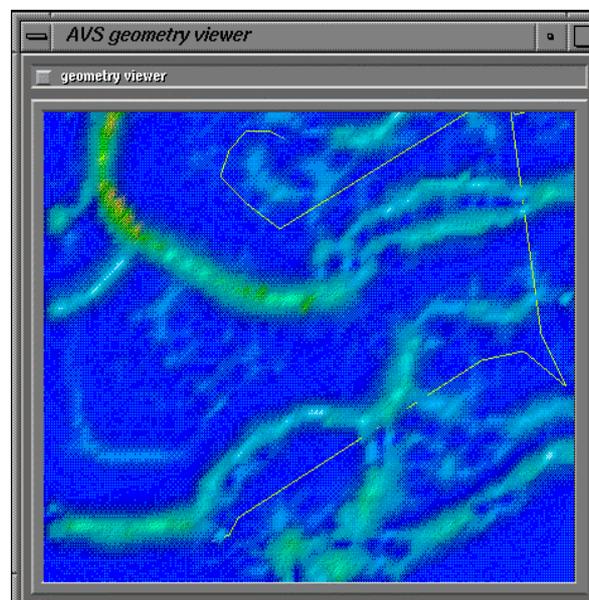


Abb.17: Weg auf einer U-Matrix mit mehreren Successions

Auf der zweiten Ebene einer hierarchischen SOM wird eine U-Matrix zur Erkennung von Events erzeugt. Ein "Tal" auf dieser U-Matrix entspricht hier denselben gleichzeitig auftretenden PrimitivePatterns. Durch Interpretation von Wegen auf einer U-Matrix der zweiten Ebene können sowohl Events als auch Sequences bzw. TemporalPatterns erkannt werden. Dabei wird ein Event dadurch identifiziert, daß ein Weg innerhalb eines bestimmten "Tals" verläuft. Die Dauer des Events kann durch das Verbleiben eines Weges in einem "Tal" festgestellt werden. Die Erkennung von Sequences bzw. TemporalPatterns durch Wege auf einer U-Matrix ist im Vergleich zur Erkennung von Successions schwieriger, da hier wiederholt auftretende Wege gesucht werden, die verschiedene Klassen bzw. Events durchlaufen.

Die Interpretation von Wegen und somit die Gewinnung von Sequences bzw. TemporalPatterns ist durch eine Visualisierung von Übergangshäufigkeiten auf einer U-Matrix möglich (s. Abb.18). Hier entspricht die Größe der Punkte der Häufigkeit des Auftretens von Events. Die Häufigkeit der Übergänge zwischen Events wird anhand einer farblichen Kodierung der Kanten zwischen den Punkten visualisiert. Rote Kanten entsprechen dabei sehr häufigen Übergängen. Der Übergang zur Farbe Blau bedeutet, daß immer weniger Übergänge zwischen Events stattfinden. Werden Sequences bzw. TemporalPatterns durch Startevents und Endevents identifiziert, so kann ein länger andauerndes Verbleiben eines Weges in Bereichen auf einer U-Matrix, die keinem Event zugeordnet worden sind, als ein mögliches Startevent bzw. Endevent interpretiert werden.

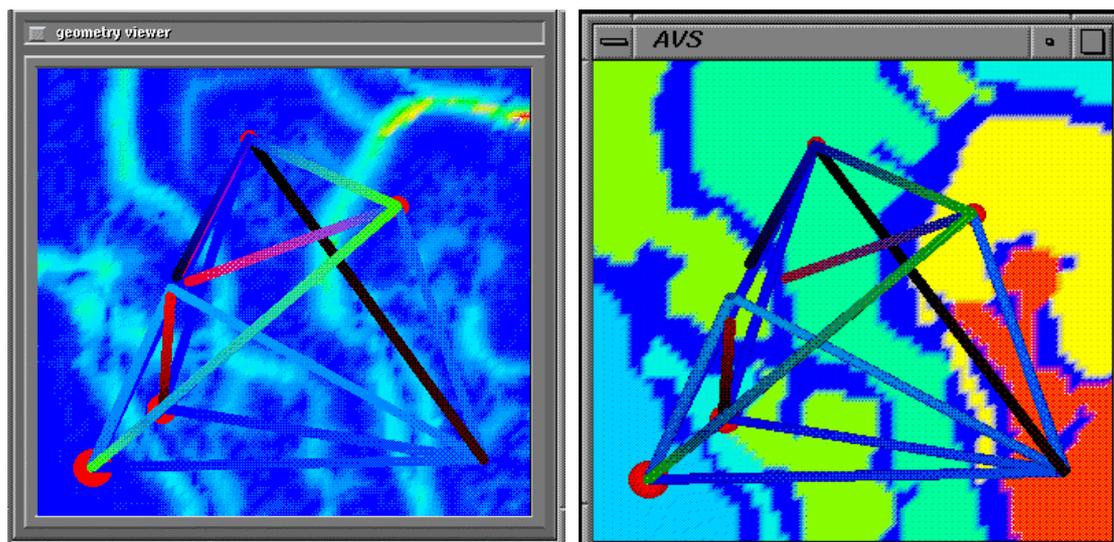


Abb.18: U-Matrix mit Übergangshäufigkeiten

Kapitel 5

Temporale Wissenskonzersion für schlafbezogene Atmungsstörungen

In diesem Kapitel wird die TWK auf schlafbezogene Atmungsstörungen (SBAS) angewendet, und es werden die dabei erzielten Ergebnisse vorgestellt. Aufgabe ist es gewesen, die TWK auf ein komplexes und schwieriges Problem anzuwenden, um die durch die TWK vorgeschlagene Vorgehensweise an einem real existierenden Beispiel zu untersuchen und zu validieren. Als Anwendungsbeispiel sind SBAS ausgewählt worden, da hier verschiedene Muster von SBAS gesucht werden, die wiederholt auftreten und die erst durch eine parallele Auswertung von Zeitreihen identifiziert werden können. Probleme bei der Auswertung von SBAS sind beispielsweise sehr unterschiedliche, individuelle Muster desselben Typs für verschiedene Patienten, wobei außerdem die Dauer der Muster stark variieren kann. Da es sich bei der TWK um eine explorative Methode handelt, durch die in einem ersten Schritt komplexe Muster der SBAS entdeckt werden, die anschließend in eine symbolische Wissensrepräsentation in Form von temporalen Regeln überführt werden, wird eine qualitative Evaluation der Ergebnisse durch eine Expertenbefragung durchgeführt. Hierbei wird die strukturelle und die semantische Korrektheit der Regeln überprüft. Zur Expertenbefragung wird in dieser Arbeit ein Fragebogen erstellt, durch den die Ergebnisse der TWK angewandt aus SBAS evaluiert werden.

In Kapitel 5.1 werden verschiedene Typen von SBAS, sowie Kriterien zur Erkennung und Beschreibung von SBAS dargestellt. Kapitel 5.2 enthält die Ergebnisse der TWK angewandt auf SBAS. In Kapitel 5.3 werden Methoden zur Evaluation der Ergebnisse der TWK sowie die Ergebnisse der Expertenbefragung dargestellt.

5.1 Schlafbezogene Atmungsstörungen (SBAS)

Die in diesem Kapitel dargestellten Beschreibungen schlafbezogener Atmungsstörungen (SBAS) sind im wesentlichen aus Penzel (1995), Roos et al.(1993), Penzel et al. (1991) entnommen worden.

Aus der Physiologie ist bekannt, daß sowohl der Schlaf die autonomen Funktionen des menschlichen Körpers beeinflusst, wie auch umgekehrt die autonome Regulation den physiologischen Schlaf [Penzel 95]. Treten Veränderungen in den autonomen Funktionen auf, so können sie Störungen des Schlafes hervorrufen. Schlafstörungen besitzen i.a. einen großen Einfluß auf die Gesundheit des Menschen. Fortschritte bei der Erkennung von Schlafstörungen wurden insbesondere durch Langzeitregistrierung und Auswertung von schlafbezogenen Atmungsstörungen (SBAS) erzielt.

SBAS führen häufig zu einer Fragmentierung des Schlafes und dadurch zu Tagesschläfrigkeit, so daß eine erhöhte Gefahr des Einschlafens während des Tages und somit eine zunehmende Sterblichkeit von Autofahrern nachgewiesen werden konnte [America 94]. Hauptsächlich sind Männer davon betroffen, wobei 1-2% aller erwachsenen Männer unter obstruktiver Apnoe leiden, der am häufigsten auftretende Krankheit unter den SBAS. Eine möglichst frühzeitige Erkennung von SBAS ist notwendig, um entsprechende Maßnahmen und Therapien durchführen zu können. Hierzu wurde das ambulante Früherkennungssystem MESAM entwickelt, durch das Patienten mit SBAS für ein Schlaflabor vorselektiert werden [Penzel et al. 90]. Durch ein MESAM werden Herzfrequenz, Sauerstoffsättigung und Schnarchgeräusche eines Patienten während einer Nacht aufgezeichnet. Durch eine Auswertung eines MESAM kann die Anzahl von Schlafstörungen während einer Nacht erkannt werden.

Durch ein MESAM können jedoch keine Aussagen über verschiedene Typen von Mustern von SBAS gemacht werden. Hierzu ist die Aufnahme von atmungsbezogenen Signalen erforderlich, die mit Hilfe der kardiorespiratorischen Polysomnographie (PSG) aufgezeichnet werden. Durch eine PSG werden insgesamt schlafbezogene Signale (EEG, EOG, EMG), atmungsbezogene Signale (Luftfluß, Thorax- und Abdomenbewegungen, SaO₂, Atemgeräusche) und kardiovaskuläre Signale (EKG, Blutdruck) aufgenommen (s. Abb.19). Durch atmungsbezogene Signale einer PSG ist die Erkennung verschiedener Typen von SBAS (Apnoen

und Hypopnoen) möglich, wobei die Summe von Apnoeindex und Hypopnoeindex als RDI (Respiratory Disturbance Index) bezeichnet wird [Penzel et al. 91]. Ist ein RDI größer als 20 Phasen/Stunde, so wird das als pathologisch angesehen. Bei einem RDI größer als 40 Phasen/Stunde liegen bereits therapiebedürftige SBAS vor. Schlafapnoen treten während einer Atmungsphase auf, wobei unter einer einzelnen Schlafapnoe ein Atemstillstand von mindestens 10 Sekunden Dauer verstanden wird.

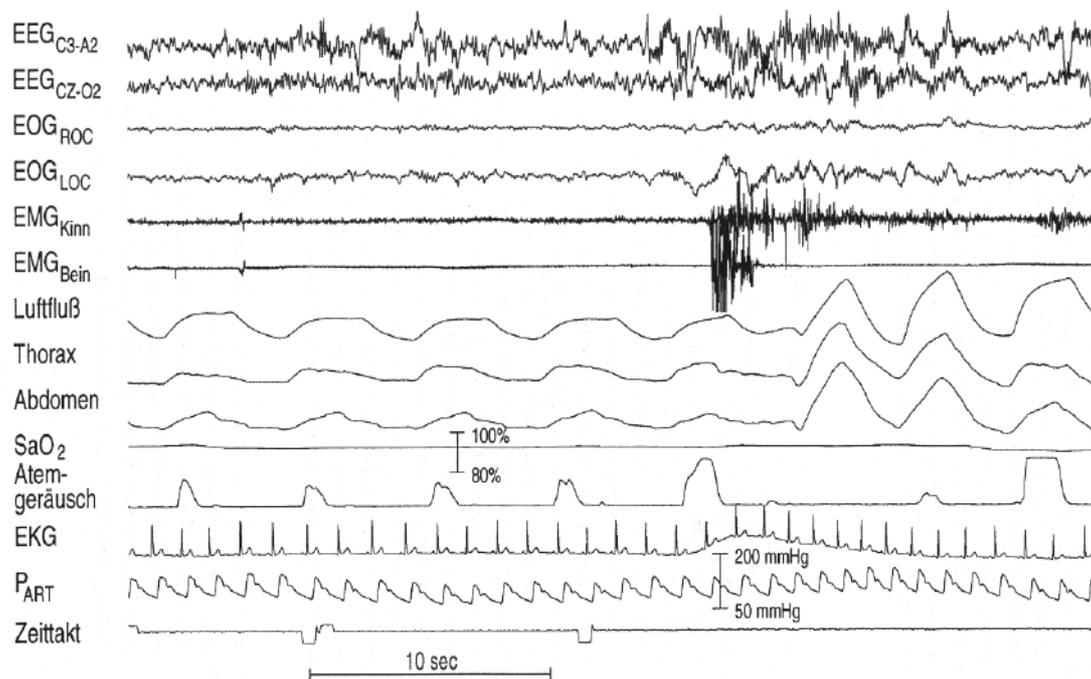


Abb.19: Ein Registrierbeispiel mit allen Kurven einer kardiorespiratorischen Polysomnographie (PSG) [in Penzel (1995)]

SBAS werden eingeteilt in SBAS *mit* Obstruktion der oberen Atemwege und in SBAS *ohne* Obstruktion der oberen Atemwege. SBAS mit Obstruktion der oberen Atemwege sind wiederum unterteilt in obstruktives Schnarchen und obstruktive Apnoe. SBAS *ohne* Obstruktion der oberen Atemwege gliedern sich in alveoläre und sekundäre alveoläre Hypoventilation und zentrale Apnoe. Die verschiedenen Krankheitsbilder (s. Abb.20) werden dabei hauptsächlich in den Signalen Atemfluß, Thorax- und Abdomenbewegungen erkannt, wobei zwischen amplitudenabhängigen Störungen mit verändertem Atemantrieb und phasenabhängigen Störungen mit veränderter Atmungskoordination unterschieden wird. Dabei können *reduzierte* amplitudenabhängige Störungen (reduziert auf mindestens 50%) oder *keine* amplitudenabhängige Störungen (reduziert auf mindestens 10-20%)

auftreten. Bei Thorax- und Abdomenbewegungen können Phasenverschiebungen um 90° (gegenläufige Atmungsbewegungen) oder keine Phasenverschiebungen (parallele Atmungsbewegungen) eintreten. Zusätzlich tritt häufig eine Unterbrechung bei den Schnarchgeräuschen auf. Die verschiedenen Typen manifestieren sich durch unterschiedliche Muster und können bei einem Patienten in Kombination vorliegen. Erst eine parallele Auswertung dieser Zeitreihen erlaubt eine sichere Unterscheidung aller unterschiedlichen Typen von SBAS [Penzel 95].

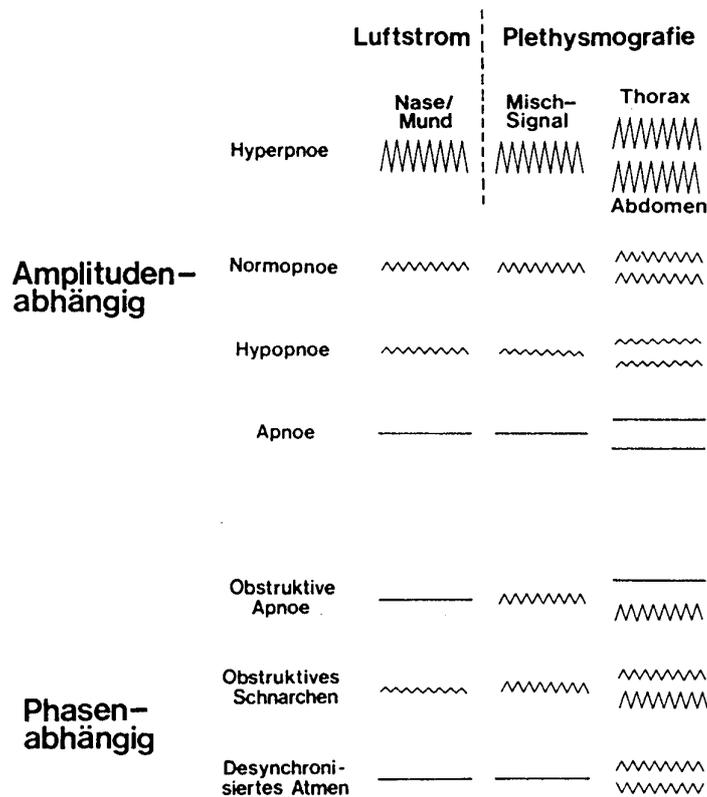


Abb.20: Schlafbezogene Atmungsstörungen (SBAS) unterteilt in amplitudenabhängige und in phasenabhängige Störungen [in Penzel (1995)]

Die Auswertung einer PSG ist sehr aufwendig und schwierig, da Patienten sehr unterschiedliche individuelle Krankheitsmuster haben können [Penzel et al. 91]. Ein zusätzliches Problem bei der Erkennung von SBAS liegt in der stark schwankenden Dauer einzelner Schlafapnoen. Zum Beispiel führen sehr lange Schlafapnoen bis zu 120 Sekunden zu einem niedrigeren RDI als kurze und häufiger auftretende Schlafapnoen mit einer Dauer von 20 bis 30 Sekunden. Dies bedeutet

jedoch nicht, daß ein niedrigerer RDI ein geringeres Risiko darstellen muß. Im Gegenteil, Patienten mit länger andauernden Schlafapnoen besitzen ein höheres Sterberisiko. Demzufolge müssen Methoden entwickelt werden, die nicht nur die Erkennung von unterschiedlichen individuellen Krankheitsmustern ermöglichen, sondern die auch in der Auswertung unterschiedlich lange Schlafapnoen berücksichtigen.

Die Auswertung von Langzeitregistrierungen von SBAS erfolgt in der Regel durch eine visuelle Klassifikation der verschiedenen Krankheitsbilder durch medizin-technische Assistenten [Roos et al. 93]. Dabei werden verschiedene Typen von SBAS, Apnoen und Hypopnoen, erkannt und die Summe von Apnoeindex und Hypopnoeindex durch den RDI (Respiratory Disturbance Index) registriert.

Bisherige Ansätze zur computergestützten Auswertung von SBAS verwenden häufig einzelne Signale wie z.B. Herzfrequenz, Blutdruck, EEG, Schnarchgeräusche, wobei Spektralanalysen, Powerspektren, Korrelationen, usw. durchgeführt werden [Penzel 95, Fett 92, Penzel et al. 91, Penzel/Petzold 89]. Dabei werden z.B. Spektralanalysen der Atemgeräusche und deren zeitliche Struktur zur Identifikation von obstruktivem Schnarchen untersucht. Die schnarchfreien Intervalle dauern bei regelmäßigem Schnarchen nur wenige Sekunden an, während sie bei einer obstruktiven Apnoe so lange wie die Apnoe andauern [Penzel et al. 90]. In einer Studie [Roos et al. 93] wurden Korrelationen von $r=0,51$ zwischen dem RDI aus schnarchfreien Intervallen und dem RDI aus der Polysomnographie berechnet. Für Sensitivität ergaben sich 87% und für Spezifität 33%. Diese Werte zeigen die prinzipiellen Grenzen für die Erkennung von obstruktivem Schnarchen anhand von schnarchfreien Intervallen.

Weitere Untersuchungen zur Auswertung von obstruktiven Apnoen wurden durchgeführt, indem verschiedene Maße aus den respiratorischen Signalen der PSG berechnet wurden [Penzel 91]. Es wurde der Zeitpunkt des Beginns der Inspiration und des Beginns der Expiration ermittelt, sowie die Atmungsamplitude gemessen. Die Methode wurde an einem Patientenkollektiv von 8 Patienten validiert. Die obstruktiven Apnoen wurden mit einer Sensitivität von 98% und einer Spezifität von 93% erkannt. Weiterhin wurde für obstruktive Apnoen die Häufigkeitsverteilung für die Dauer der Schlafapnoen berechnet [Penzel 95]. Dabei wurden drei Gruppen von Patienten identifiziert:

1. Patienten, bei denen umso weniger Apnoen vorlagen, je länger die Apnoen andauerten.
2. Patienten, die eine typische mittlere Apnoedauer von 30 bis 40 Sekunden aufwiesen.

3. Patienten, bei denen eine bimodale Mischform der genannten Verteilungsmuster gefunden wurde.

Eine weitere Auswertung berücksichtigte die Auswirkung von Schlafstadien auf Schlafapnoen [Penzel 95]. Schlafapnoen im REM-Schlaf unterscheiden sich deutlich von Schlafapnoen im NREM-Schlaf. Im Mittel waren Schlafapnoen im REM-Schlaf länger als in allen anderen Schlafstadien, und die Sauerstoffsättigungsabfälle größer. Am auffälligsten ist die Unregelmäßigkeit von Schlafapnoen, wobei sich sehr lange Schlafapnoen von bis zu zwei Minuten Dauer mit sehr kurzen Schlafapnoen von ca. 20 Sekunden Dauer abwechseln.

Beschreibungen von SBAS liegen in der Medizin nur vereinzelt vor. Zum Beispiel liefern folgende Kriterien zur visuellen Auswertung eine Beschreibung von Schlafapnoen:

- a) "periodisch auftretende, schnarchfreie Intervalle von mindestens 10 Sekunden Dauer,
- b) zyklische Variation der Herzfrequenz,
- c) Abfall der Sauerstoffsättigung um mehr als 4%.

Wenn alle drei Kriterien zeitgleich erfüllt waren und die Sauerstoffsättigung schneller als 4% je Minute abfiel, wurde eine Apnoe gezählt. Wenn nur zwei der Kriterien erfüllt waren oder die Sättigung langsamer abfiel, wurde eine Hypopnoe gezählt.“ ([Penzel 95], S. 73).

Beschreibungen von SBAS für Signale einer PSG existieren z.B. für obstruktive Apnoe. Für Schlafapnoen i.a. wird behauptet, daß "die Atmungsstörungen in den meisten Fällen mit Schnarchen einhergehen" und "pathologische Sättigungsabfälle von mehr als 4%" gefunden wurden ([Penzel 95], S. 69f). Eine obstruktive Apnoe wird dann folgendermaßen beschrieben ([Penzel 95], S. 70): "Die Phasen sind gekennzeichnet durch lang anhaltende Schnarchperioden, begleitet von Desaturation und Arousalreaktionen. Die Arousalreaktionen lassen sich durch das Ende des Schnarchens, den plötzlichen Anstieg der Sauerstoffsättigung, im tiefen Atemzug in der Polysomnographie und in dem Anstieg der Herzfrequenz bei einem Abbruch des Schnarchens in der Registrierung des MESAM-Gerätes erkennen.“

Eine weitere Möglichkeit zur Beschreibung von SBAS liefert ein Schema, bei welchen zwischen amplitudenabhängige Störungen mit verändertem Atemantrieb und phasenabhängige Störungen mit veränderter Atmungskoordination unter-

schieden werden (s. Abb. 20, S. 86). Diese Beschreibung liefert jedoch keine detaillierte Beschreibung des gesamten Verlaufes von Schlafapnoen. Das ist insbesondere von Bedeutung, wenn Mischformen der verschiedenen Krankheitsbilder vorkommen, wie z.B. bei der gemischten Apnoe (s. Kapitel 5.3.3).

Außerdem können Beschreibungen von SBAS durch Befragung eines Experten der Anwendung gewonnen werden. Ein medizinischer Experte kann dabei in einem Gespräch eine Beschreibung der verschiedenen Schlafapnoen bei genauer Betrachtung der Langzeitregistrierungen von SBAS liefern. In einem solchen Gespräch kann außerdem durch spezielle Interviewtechniken das Wissen des Experten erfragt werden, so daß es in einen geeigneten Formalismus überführt werden kann. Dieser Prozeß wird als Wissensakquisition bezeichnet. Wissensakquisition ist dennoch ein langwieriger und mühsamer Prozeß, bei dem anwendungsbezogenes Wissen eines Experten durch Interviewtechniken in mehreren Schritten systematisch erfaßt wird [Scott et al.91].

5.2 Erkennung und Beschreibung von SBAS durch die TWK

In diesem Kapitel wird die TWK auf SBAS angewendet. Es wird aufgezeigt, welche Schritte auf den verschiedenen Abstraktionsebenen der TWK durchgeführt, und welche Ergebnisse dadurch erzielt worden sind.

5.2.1 Vorverarbeitung und Merkmalsextraktion

In diesem Kapitel werden die durchgeführten Vorverarbeitungsschritte vorgestellt. In der Arbeitsgruppe von Prof. J.H. Peter des Schlaflabors des Uni-Klinikums in Marburg sind Langzeitregistrierungen einer kardiorespiratorischen Polysomnographie (PSG) von drei Patienten mit relevanten Mustern von SBAS ausgewählt worden. Kriterien aus der Anwendung legten die jeweilige Auswahl der Merkmale nahe. Für die Merkmalsextraktion werden daher amplitudenabhängige Störungen und phasenabhängige Störungen mit veränderter Atmungskoordinaten für Thorax- und Abdomenbewegungen berücksichtigt (s. Abb.20, S. 86). Weiterhin wird eine Reskalierung der Schnarchgeräusche vorgenommen sowie

eine Sauerstoffentsättigung von mehr als 4% für die letzten 10 Sekunden erkannt.

Bei diesem Datensatz handelt es sich um eine Langzeitregistrierung atmungsbezogener Signale einer kardiorespiratorischen Polysomnographie (PSG) von mehreren Patienten, der von der Arbeitsgruppe von Prof. J.H. Peter des Schlaflabors des Uni-Klinikums in Marburg zur Verfügung gestellt worden ist. Insgesamt werden Zeitausschnitte von Registrierungen von drei Patienten mit SBAS betrachtet, die relevante Muster aufweisen (s. a. Anhang A.1). Die verschiedenen Typen von Mustern der SBAS sind uns nicht bekannt, da sie explorativ durch die TWK entdeckt werden sollen. Zur Gewinnung der TemporalPatterns werden folgende Zeitausschnitte verwendet:

- Patient 1: von 0:10:00 bis 0:16:00 (10 SBAS)
- Patient 1: von 2:15:00 bis 2:21:00
- Patient 2: von 2:15:00 bis 2:21:00 (9 SBAS)
- Patient 3: von 3:56:00 bis 4:04:00 (7 SBAS)

Vor der Merkmalsextraktion werden die in den Zeitreihen auftretenden Fehler eliminiert. Beispielsweise enthalten Schnarchgeräusche unterschiedliche Nullpunkte. Durch eine Reskalierung erhalten alle Patienten für die Schnarchgeräusche denselben Nullpunkt. Außerdem werden Unterbrechungen bei der Aufnahme der Sauerstoffsättigung festgestellt.

Kriterien aus der Anwendung legen nahe, Merkmale aus den Zeitreihen zu extrahieren, bei denen amplitudenabhängige Störungen berücksichtigt werden. Amplitudenabhängige Störungen sind dadurch charakterisiert, daß die Amplitude des Atemflusses und der Thorax- und Abdomenbewegungen um mehr als 50% (reduzierte Atmung) bzw. um mehr als 10-20% (keine Atmung) der normalen Amplitude reduziert ist [Penzel 95]. Daher wird für die Zeitreihen *Atemfluß*, *Thoraxbewegungen* und *Abdomenbewegungen* das Volumen berechnet. Das *Atemvolumen* wird folgendermaßen bestimmt:

$$Atemvol(t) = \sum_{i=t-d}^{t+d} |Atemfluss(i+1) - Atemfluss(i)| \quad \text{und} \quad (5.2.1)$$

$$Atemvolumen(t) = \frac{\sum_{i=t-d}^{t+d} Atemvol(i)}{\|Atemvol(i)\|} \quad (5.2.2)$$

Dabei ist $2*d+1$ die Größe des Zeitfensters. In diesem Beispiel ist $d = 2$ gewählt worden, was einem Atemzug entspricht. Dieselbe Transformation wird auf den Zeitreihen *Thorax- und Abdomenbewegungen* durchgeführt.

Die Verteilungen der berechneten Transformationen auf den Zeitreihen *Atemfluß* und *Thorax- und Abdomenbewegungen* werden anhand von Histogrammen untersucht. Dabei werden multimodale Verteilungen für die amplitudenabhängigen Störungen festgestellt. Um die multimodalen Verteilungen in der Merkmalsextraktion zu berücksichtigen, werden aus den Histogrammen Zugehörigkeitsfunktionen bestimmt (s. Abb.21, Abb.22 und Abb.23), die durch die linguistischen Terme *kein*, *reduziert* oder *groß* bzw. *stark* beschrieben werden. Der Vorteil bei der Verwendung von Zugehörigkeitsfunktionen ist die Vermeidung von harten Aussagen durch Erzeugung von unscharfen Mengen [Zadeh 65]. Durch die linguistischen Terme werden für Menschen verständlichen Merkmale in einer sprachlichen Form gewonnen. Außerdem wird durch die Zugehörigkeitsfunktionen eine Normierung der Zeitreihen auf einen Wertebereich von $[0,1]$ erreicht.

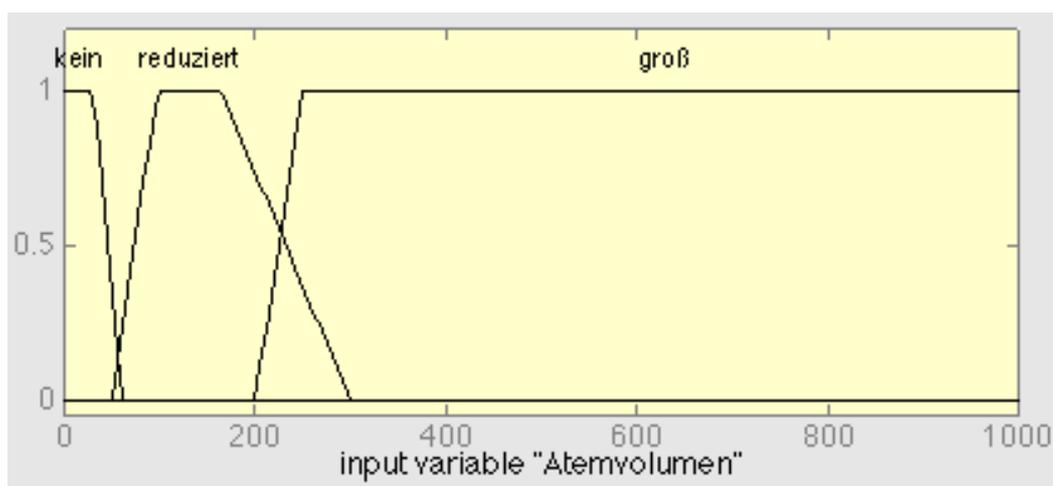


Abb.21: Fuzzy-Membership-Funktionen für *Atemvolumen*

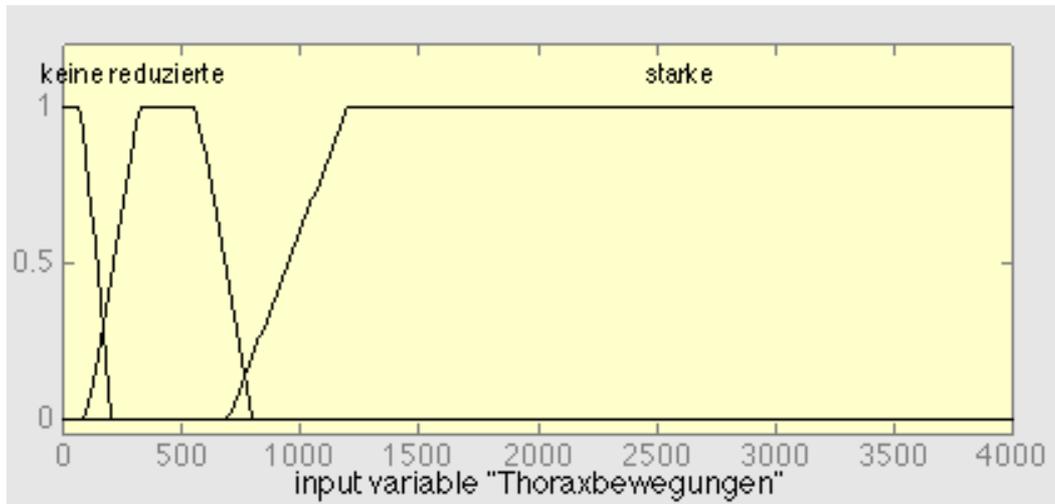


Abb.22: Fuzzy-Membership-Funktionen für *Thoraxbewegungen*

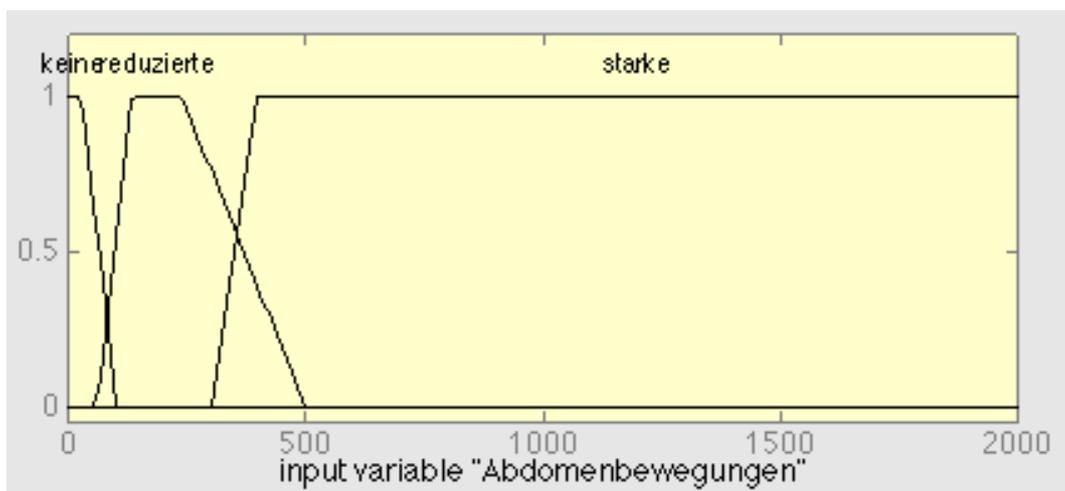


Abb.23: Fuzzy-Membership-Funktionen für *Abdomenbewegungen*

Weitere Kriterien aus der Anwendung legen nahe, phasenabhängige Störungen in Thorax- und Abdomenbewegungen durch die Merkmalsextraktion zu berücksichtigen (s. Abb.20, S. 86). Hierzu werden Kreuzkorrelationen zwischen den Zeitreihen *Thoraxbewegungen* und *Abdomenbewegungen* mit einem Zeitfenster der Größe $d = 8$ berechnet. Für die Gewinnung dieses Merkmals werden nur die Korrelationswerte der Verzögerungen (engl. lag) von -1,0,1 berücksichtigt, die dann

gemittelt werden. Ein Histogramm über die Verteilung der Kreuzkorrelationen (s. Abb.24) zeigt, daß eine Unterscheidung zwischen gegenläufigen und parallelen Thorax- und Abdomenbewegungen durch eine solche Transformation möglich ist. Außerdem wird dadurch eine Normierung auf den Wertebereich von $[-1,1]$ erreicht.

Die Identifikation von SBAS beruht darauf, daß eine Unterbrechung von Schnarchgeräuschen auftritt [Penzel 95]. Da der Nullpunkt der Zeitreihe für die Atmungsgeräusche variiert, wird ein allgemeiner Nullpunkt festgelegt, so daß Abweichungen vom Nullpunkt als Schnarchgeräusche interpretiert werden. Starke Schnarchgeräusche treten auf, falls die Abweichungen vom Nullpunkt ca. 2200 Einheiten betragen. Außerdem wird für alle Patienten eine Reskalierung der Schnarchgeräusche vorgenommen, so daß keine Schnarchgeräusche um den Wert 0 liegen und starke Schnarchgeräusche um den Wert 1.

Zur Erkennung verschiedener Krankheitsbilder von SBAS sind die Zeitreihen *Atemfluß*, *Thorax - und Abdomenbewegungen* und *Schnarchgeräusche* ausreichend (s. Abb. 20, S. 86). Es muß nur noch überprüft werden, ob während einer Apnoe oder Hypopnoe die Sauerstoffsättigung um mindestens 4% in den letzten 10 sec abfällt [Penzel 95]. Zur Vorverarbeitung der Sauerstoffsättigung werden drei Werte berechnet: der Wert 0 steht für keine Sauerstoffentsättigung, der Wert 0,5 für das Auftreten einer Sauerstoffentsättigung während der letzten 10 Sekunden und der Wert 1 für das Auftreten von Meßfehlern. Dieses Merkmal wird nicht zur Entdeckung von TemporalPatterns verwendet. Es kann hierdurch lediglich überprüft werden, ob überhaupt ein Sauerstoffsättigungsabfall während einer Schlafapnoe stattgefunden hat.

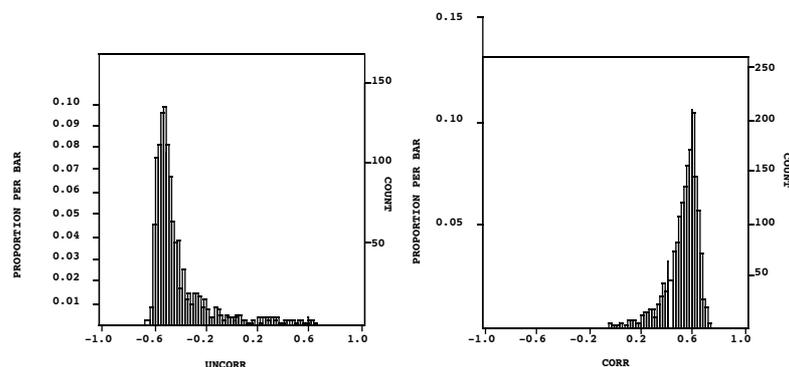


Abb.24: Histogramme für Kreuzkorrelationen aus Daten mit (a) gegenläufigen (uncorr) und (b) parallelen (corr) Thorax- und Abdomenbewegungen

Als letzter Schritt ist eine Vorverarbeitung der extrahierten Merkmale für eine Strukturanalyse der Merkmale erforderlich [Ultsch 91]. Zunächst wird die Verteilung der Merkmale betrachtet. Bei der Gewinnung von Zugehörigkeitsfunktionen aus den Histogrammen ist die Verteilung der Merkmale häufig treppenförmig. Es ist also keine Transformationen angewendet worden. Bei einer Analyse von Boxplots über alle Merkmale werden keine Ausreißer festgestellt. Auch geben verschiedene Ausreißertests keine Hinweise auf Ausreißer. Es werden keine korrelierten Merkmale identifiziert. Da alle Merkmalsfolgen im Wertebereich von $[-1,1]$ liegen, wird keine Normierung der Daten durchgeführt.

Zusammengefaßt werden durch die o.g. Vorverarbeitungsschritte folgende Merkmale berechnet: *Atemvolumen-groß* $\in [0,1]$, *Atemvolumen-reduziert* $\in [0,1]$, *Atemvolumen-kein* $\in [0,1]$, *Thorax-stark* $\in [0,1]$, *Thorax-reduziert* $\in [0,1]$, *Thorax-kein* $\in [0,1]$, *Abdomen-stark* $\in [0,1]$, *Abdomen-reduziert* $\in [0,1]$, *Abdomen-kein* $\in [0,1]$, *ThoraxAbdomen-Phase* $\in [-1,1]$, *Schnarchintensität* $\in [0,1]$ und *Sauerstoffentsättigung* mit den Werten 0, 0.5, 1.

5.2.2 Gewinnung von PrimitivePatterns durch eine Strukturanalyse

In diesem Kapitel werden zwei U-Matrizen, bezeichnet als *AirflowUMX* und *Thorax-AbdomenUMX*, zur Erkennung von PrimitivePatterns eingesetzt. Durch die U-Matrix *AirflowUMX* werden PrimitivePatterns aus Selektionen von Merkmalen bestimmt, die im wesentlichen den Atemfluß betreffen. Durch die U-Matrix *ThoraxAbdomenUMX* werden PrimitivePatterns aus Selektionen von Merkmalen bestimmt, die im wesentlichen Thorax- und Abdomenbewegungen betreffen.

Es werden folgende Selektionen von Merkmalen ausgewählt:

1. Merkmale, die im wesentlichen den Atemfluß betreffen: *Atemvolumen-groß*, *Atemvolumen-reduziert*, *Atemvolumen-kein*, *ThoraxAbdomen-Phase*, *Schnarchintensität*.
2. Merkmale, die im wesentlichen Thorax- und Abdomenbewegungen betreffen: *Thorax-stark*, *Thorax-reduziert*, *Thorax-kein*, *Abdomen-stark*, *Abdomen-reduziert*, *Abdomen-kein*, *ThoraxAbdomen-Phase*, *Schnarchintensität*.

Beide SOM sind mit folgenden Parametern angelernet worden: 64x64 Matrix, 400 tausend Lernschritte, toroid angelernet. Für beide SOM sind durch die Two-Match-

Methode (s. Kapitel 2.1.2) die beiden U-Matrizen, *AirflowUMX* (s. Abb.25) und *ThoraxAbdomenUMX* (s. Abb.27), berechnet worden. Die mit Hilfe der U-Matrix durchgeführten Klassifikationen sind in Abb.26 und in Abb.28 dargestellt. Insgesamt werden 6 Klassen durch *AirflowUMX* und 9 Klassen durch *ThoraxAbdomenUMX* entdeckt. Die Klassen werden durchnummeriert. Jede PrimitivePattern-Klasse wird durch einen Namen identifiziert, die PrimitivePattern-Klassen der *AirflowUMX* mit den Namen *A1* bis *A6* (s. Abb.26) und die PrimitivePattern-Klassen der *ThoraxAbdomenUMX* mit den Namen *B1* bis *B9* (s. Abb.28). Alle anderen Bereiche auf den U-Matrizen werden der Klasse *Tacet* zugeordnet. Es werden ihnen die Namen *A0* bzw. *B0* gegeben.

Eine Strukturanalyse beinhaltet nicht nur die Entdeckung von Klassen. Jeder Klasse wird nach Möglichkeit zusätzlich ein für die Anwendung bedeutsamer Name gegeben. Im Rahmen dieser Arbeit wird vorgeschlagen, bedeutsame Namen für PrimitivePatterns aus den durch den Regelgenerierungsalgorithmus sig* [Ultsch 91] erzeugten Regeln abzuleiten:

1. Für jede PrimitivePattern-Klasse wird eine sig*-Regel erzeugt. Jede PrimitivePattern-Klasse wird damit durch ihre signifikanten Merkmale beschrieben.
2. Für jedes Merkmal wird durch die sig*-Regel ein Wertebereich angegeben, der für die Merkmale unterschiedlich interpretiert wird.

Beispiele:

Atemvolumen-groß = 0,8 bedeutet, daß *Atemvolumen-groß* sehr wahrscheinlich eintritt.

Thorax-kein = 0,1 bedeutet, daß *Thorax-kein* sehr wahrscheinlich nicht eintritt.

ThoraxAbdomen-Phase = - 0,4 bedeutet, daß *Thorax- und Abdomenbewegungen* gegenläufig sind.

Schnarchintensität = 0,9 bedeutet, daß *starke Schnarchgeräusche* auftreten.

3. Durch Änderung des Kumulationswertes zur Erzeugung von sig*-Regeln können weitere Merkmale einbezogen werden, falls die bisherigen Merkmale zur Namensgebung nicht ausreichen.
4. Redundante Merkmale dürfen für die Namensgebung unberücksichtigt bleiben.

Beispiel:

Atemvolumen-groß = 0,9 und *Atemvolumen-kein* = 0.

Eines der beiden Merkmale ist überflüssig und wird für die Gewinnung des Namens nicht berücksichtigt.

Für die PrimitivePatterns der *AirflowUMX* werden aus den sig*-Regeln (s. Anhang A.6) folgende Namen hergeleitet:

- *A1: reduziertes Atemvolumen mit Schnarchgeräuschen* (Abk. *reAVmS*)
- *A2: kein Atemvolumen ohne Schnarchgeräusche* (Abk. *keAVoS*)
- *A3: geringes Atemvolumen ohne Schnarchgeräusche* (Abk. *geAVoS*)
- *A4: großes Atemvolumen mit Schnarchgeräuschen* (Abk. *grAVmS*)
- *A5: reduziertes Atemvolumen ohne Schnarchgeräusche* (Abk. *reAVoS*)
- *A6: geringes Atemvolumen ohne Schnarchgeräusche* (Abk. *geAVoS*)

Für die PrimitivePatterns der *ThoraxAbdomenUMX* werden aus den sig*-Regeln folgende Namen hergeleitet (s. Anhang A.6):

- *B1: reduzierte parallele Thorax- und Abdomenbewegungen mit Schnarchgeräuschen* (Abk.: *reparTABmS*)
- *B2: reduzierte parallele Thorax- und Abdomenbewegungen* (Abk.: *reparTAB*)
- *B3: keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche* (Abk.: *keTABoS*)
- *B4: gegenläufige Thorax- und Abdomenbewegungen* (Abk.: *gegTAB*)
- *B5: reduziert bis stark gegenläufige Thorax- und Abdomenbewegungen* (Abkz.: *re-stgegTAB*)
- *B6: starke Thorax- und Abdomenbewegungen* (Abk.: *stTAB*)
- *B7: keine-starken gegenläufigen Thorax- und Abdomenbewegungen* (Abk.: \neg *stgegTAB*)
- *B8: reduzierte Thoraxbewegungen und keine Abdomenbewegung ohne Schnarchgeräusche* (Abk.: *reTBkeABoS*)
- *B9: reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche* (Abk.: *repargegTABoS*)

Im folgenden werden die Abkürzungen für die Namen der PrimitivePatterns z.B. in Tabellen verwendet, wenn die Bedeutung der Namen der PrimitivePatterns nicht im Vordergrund steht.

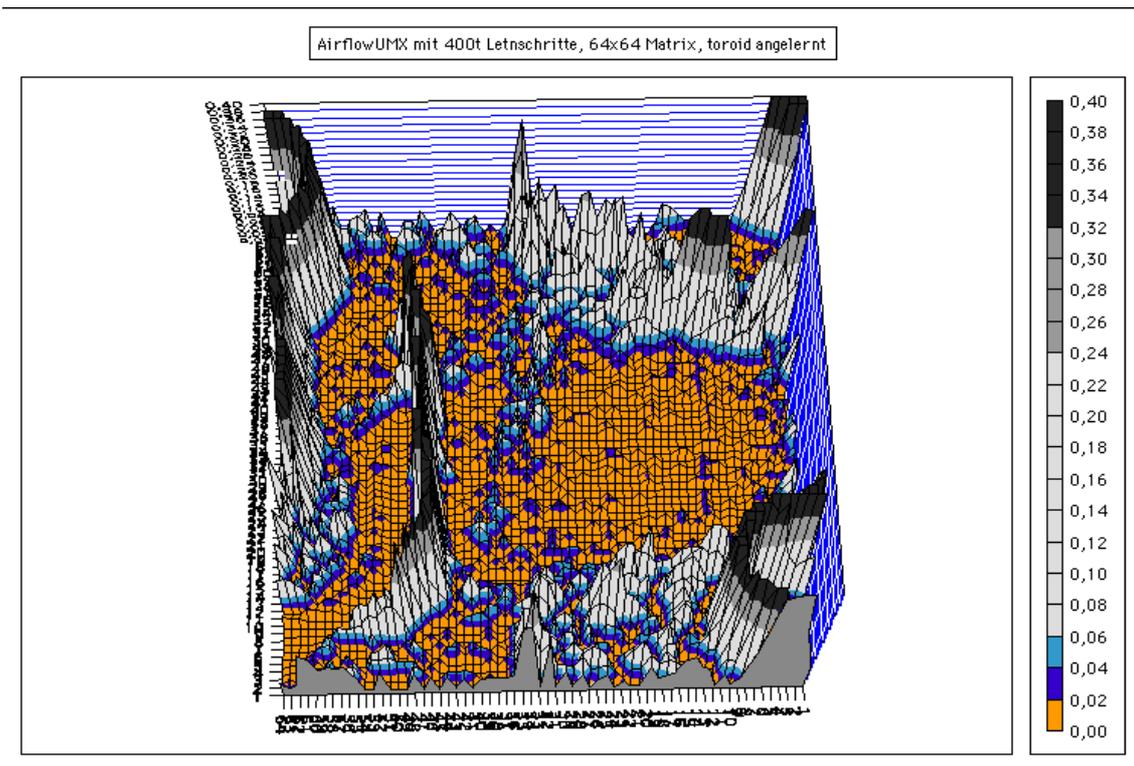


Abb.25: *AirflowUMX*, 64x64 Matrix, 400 tausend Lernschritte, toroid angelernt.

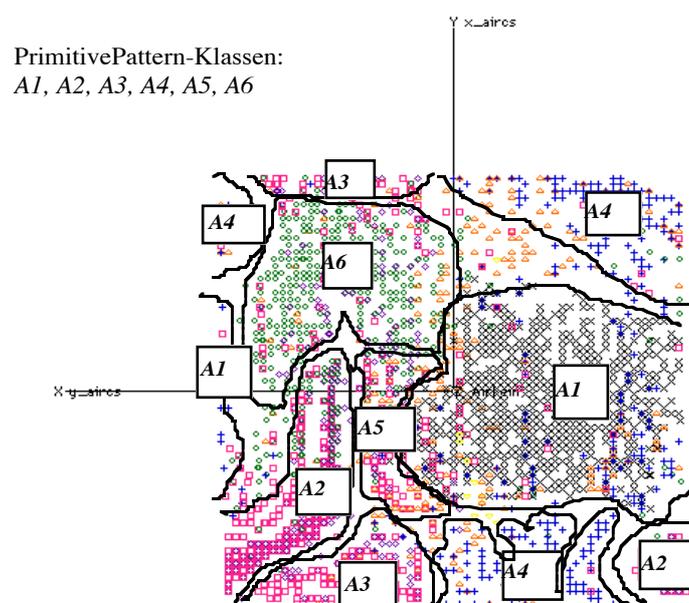


Abb.26: PrimitivePattern-Klassen der *AirflowUMX*

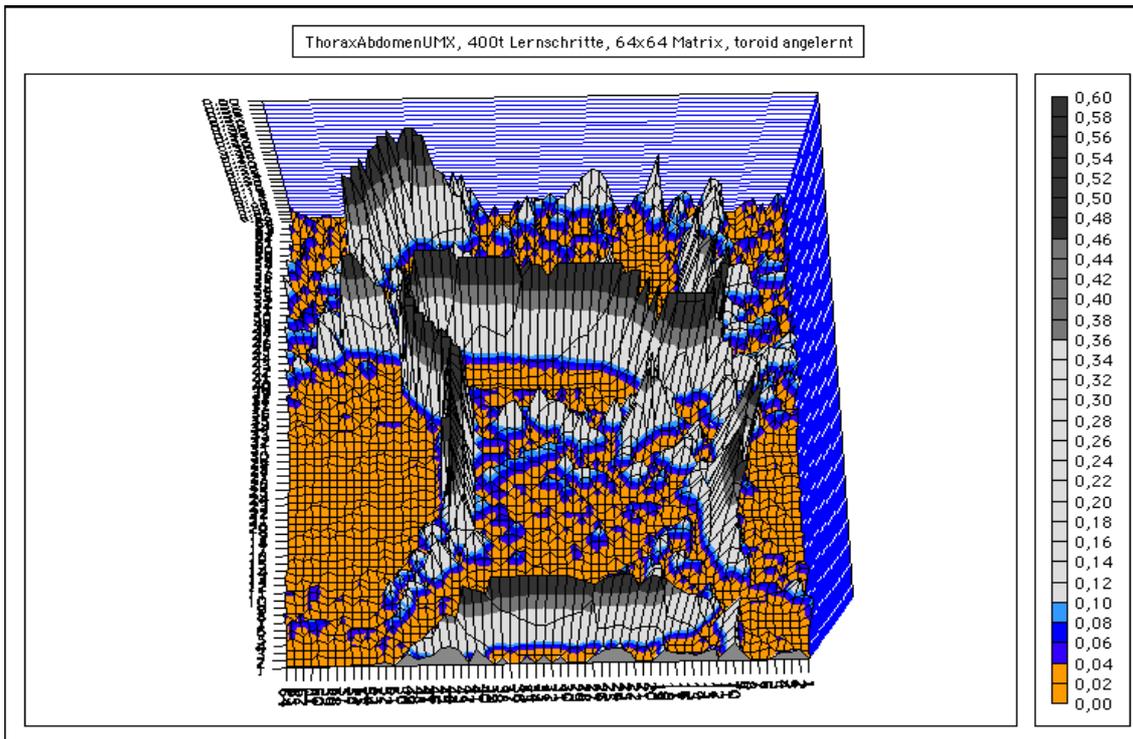


Abb.27: *ThoraxAbdomenUMX*, 64x64 Matrix, 400 tausend Lernschritte, toroid angelernt.

PrimitivePattern-Klassen:
B1, B2, B3, B4, B5, B6, B7, B8, B9

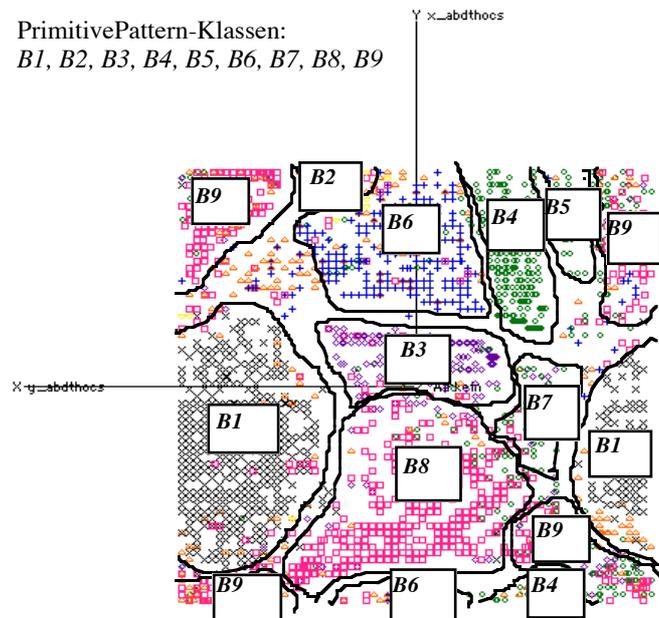


Abb.28: PrimitivePattern-Klassen der *ThoraxAbdomenUMX*

5.2.3 Erkennung von Successions

In diesem Schritt der TWK werden unmittelbar aufeinanderfolgende gleiche PrimitivePatterns auf der *AirflowUMX* bzw. auf der *ThoraxAbdomenUMX* zu Successions zusammengefaßt. Successions erhalten denselben Namen wie die in den Successions unmittelbar aufeinanderfolgenden gleichen PrimitivePatterns.

Störungen in den Successions werden nach Identifikation durch Filter eliminiert. Dabei werden sehr kurze Successions entfernt, und sehr kurze Unterbrechungen in einer Succession bleiben unberücksichtigt. Anhand von Histogrammen werden die sehr kurzen Successions identifiziert (s. Anhang A.3). Dabei werden Successions, die wie in Tabelle 1 und Tabelle 2 angegeben eine kürzere Dauer haben, in Tacets überführt.

Die PrimitivePattern-Klasse *B2: reduzierte parallele Thorax- und Abdomenbewegungen* der *ThoraxAbdomenUMX* wird nicht mehr betrachtet, da hier alle Successions sehr kurz sind. Die PrimitivePatterns dieser Klasse werden in Tacets überführt. Außerdem werden die PrimitivePattern-Klassen *B4: gegenläufige Thorax- und Abdomenbewegungen*, *B5: reduzierte bis starke gegenläufige Thorax- und Abdomenbewegungen* und *B7: keine-starken gegenläufigen Thorax- und Abdomenbewegungen* der *ThoraxAbdomenUMX* zu *B4: gegenläufige Thorax- und Abdomenbewegungen* zusammengefaßt, da es sich hier um sehr ähnliche PrimitivePattern-Klassen handelt. Dieses kann zum einen auf die Merkmale für die PrimitivePatterns in den sig*-Regeln und zum anderen auf die Nachbarschaften dieser Klassen auf der *ThoraxAbdomenUMX* zurückgeführt werden (s. Abb.28).

Succession	Dauer
<i>A1: reAVmS</i>	≤ 2 sec
<i>A2: keAVoS</i>	≤ 4 sec
<i>A3: geAVoS</i>	$\leq 1,75$ sec
<i>A4: grAVmS</i>	≤ 3 sec
<i>A5: reAVoS</i>	$\leq 2,5$ sec
<i>A6: geAVoS</i>	≤ 3 sec

Tabelle 1: Dauer von sehr kurzen Successions aus *AirflowUMX*

Succession	Dauer
<i>B1: reparTABmS</i> (1)	≤ 1 sec
<i>B2: reparTAB</i> (2)	----
<i>B3: keTABoS</i> (3)	≤ 2 sec
<i>B4: gegTAB</i> (4)	≤ 2 sec
<i>B6: stTAB</i> (6)	≤ 4 sec
<i>B8: reTBkeABoS</i> (8)	≤ 2 sec
<i>B9: repargegTABoS</i> (9)	≤ 3 sec

Tabelle 2: Dauer von sehr kurzen Successions aus *ThoraxAbdomenUMX*

Alle sehr kurzen Unterbrechungen innerhalb von Successions mit $\leq 15\%$ der Gesamtdauer der Succession werden als Störungen aufgefaßt und folgendermaßen beseitigt: Unterbricht Succession 'B' Succession 'A' kurzfristig, so wird Succession 'B' in 'A' überführt (s. Abb.29).

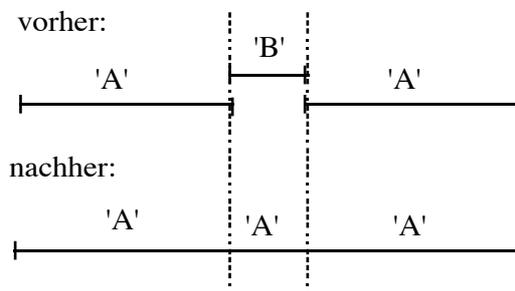


Abb.29: Eliminierung von sehr kurzen Unterbrechungen in Successions

5.2.4 Erkennung von Events durch ungefähr gleichzeitige Successions

In diesem Schritt sollen ungefähr gleichzeitige Successions erkannt und zu Events zusammengefaßt werden. Zur Erkennung von Events reicht es aus, das gleichzeitige Auftreten von Successions zu identifizieren, da insgesamt nur sehr kleine Abweichung bei ungefähr gleichzeitigen Successions auftreten dürfen (s. Definition 3.1.6). Hierzu wird zunächst die Anzahl von gleichzeitig auftretenden Primitive-Patterns aus *AirflowUMX* und *ThoraxAbdomenUMX* bestimmt (s. Anhang A.5). Um bedeutsame Events identifizieren zu können, werden empirisch bedingte Wahrscheinlichkeiten sowohl für die Primitive-Patterns aus *AirflowUMX* (s. Tabelle 3) als auch für die Primitive-Patterns aus *ThoraxAbdomenUMX* (s. Tabelle 4) bestimmt. Die berechneten Größen sind Grundlage für die Unterscheidung zwischen sehr häufigen Events (s. Tabelle 5) und weniger häufigen Events (s. Tabelle 6).

bedingte Häufigkeiten $P(A_i B_j)$	$A1:$ <i>reAV-</i> <i>mS</i>	$A2:$ <i>keAV-</i> <i>oS</i>	$A3:$ <i>geAV-</i> <i>oS</i>	$A4:$ <i>grAV-</i> <i>mS</i>	$A5:$ <i>reAV-</i> <i>oS</i>	$A6:$ <i>geAV-</i> <i>oS</i>	$A0:$ <i>Tacet</i>
$B1:$ <i>reparTABmS</i>	0,97	0,02	0	0	0	0,01	0
$B3:$ <i>keTABoS</i>	0	0,75	0,035	0	0,05	0,055	0,11
$B4:$ <i>gegTAB</i>	0	0,01	0	0	0,065	0,885	0,04
$B6:$ <i>stTAB</i>	0,16	0,01	0	0,56	0,04	0	0,23
$B8:$ <i>reTBkeABoS</i>	0	0,98	0	0	0	0,01	0,01
$B9:$ <i>repargegTABoS</i>	0	0,135	0,225	0	0,11	0,12	0,41
$B0:$ <i>Tacet</i>	0,14	0,125	0,05	0,08	0,13	0,065	0,41

Tabelle 3: Empirische bedingte Wahrscheinlichkeiten $P(A_i | B_j)$ für die Primitive-Patterns aus *AirflowUMX*.

Bedingte Häufigkeiten $P(B_j A_i)$	$A1:$ <i>reAV-</i> <i>mS</i>	$A2:$ <i>keAV-</i> <i>oS</i>	$A3:$ <i>geAV-</i> <i>oS</i>	$A4:$ <i>grAVm</i> <i>S</i>	$A5:$ <i>reAV-</i> <i>oS</i>	$A6:$ <i>geAV-</i> <i>oS</i>	$A0:$ <i>Tacet</i>
$B1:$ <i>reparTABmS</i>	0,84	0,02	0	0	0	0,01	0,01
$B3:$ <i>keTABoS</i>	0	0,31	0,10	0	0,10	0,05	0,07
$B4:$ <i>gegTAB</i>	0	0	0	0	0,12	0,73	0,025
$B6:$ <i>stTAB</i>	0,09	0,01	0	0,89	0,14	0,01	0,25
$B8:$ <i>reTBkeABoS</i>	0	0,53	0	0	0	0,01	0,01
$B9:$ <i>reparegegTABoS</i>	0	0,06	0,69	0	0,24	0,11	0,27
$B0:$ <i>Tacet</i>	0,07	0,07	0,21	0,11	0,40	0,08	0,365

Tabelle 4: Empirische bedingte Wahrscheinlichkeiten $P(B_j | A_i)$ für die Primitive-Patterns aus *ThoraxAbdomenUMX*

Hierzu werden heuristische Schwellen festgelegt, die mit Hilfe eines Histogramms bestimmt werden (s. Abb.30). Als sehr häufige Events werden diejenigen Events identifiziert, für die $P(A_i | B_j) \geq 0,5$ oder $P(B_j | A_i) \geq 0,5$ gilt. Als weniger häufige werden diejenigen Events identifiziert, für die $0,12 \leq P(A_i | B_j) < 0,5$ oder $0,11 \leq P(B_j | A_i) < 0,5$ gilt.

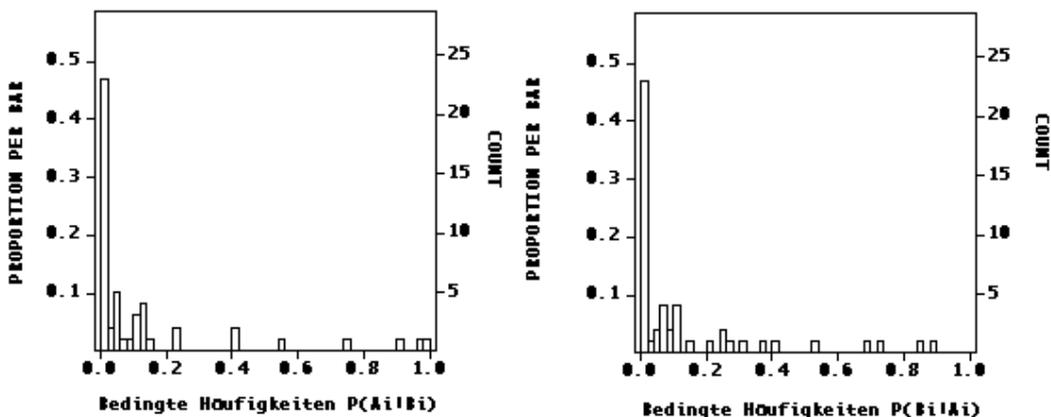


Abb.30: Histogramm für die empirischen bedingten Wahrscheinlichkeiten $P(A_i | B_j)$ und $P(B_j | A_i)$ der gleichzeitig auftretenden PrimitivePatterns aus *AirflowUMX* und *ThoraxAbdomenUMX*

Weniger häufige Events werden im einem nächsten Schritt sehr häufigen Events zugeordnet. Ziel ist es dabei, Events auf wesentliche Ereignisse in multivariaten Zeitreihen zu reduzieren. Es werden nur Events zusammengefaßt, bei denen eine große Übereinstimmung der Merkmale in den sig*-Regeln für die PrimitivePatterns existiert (s. Anhang A.5). Bei Events, die ein Tacet enthalten, besteht eine Übereinstimmung von genau einem PrimitivePattern bzw. einer Succession. Somit bestehen Events aus Alternativen von ungefähr gleichzeitigen Successions.

Successions in <i>Air-flowUMX</i>	Successions in <i>ThoraxAbdomenUMX</i>	Events
<i>A1: reduziertes Atemvolumen mit Schnarchgeräuschen</i>	<i>B1: reduzierte parallele Thorax- und Abdomenbewegungen mit Schnarchgeräuschen</i>	<i>Event 1</i>
<i>A2: kein Atemvolumen ohne Schnarchgeräusche</i>	<i>B3: keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	<i>Event 2</i>
<i>A2: kein Atemvolumen ohne Schnarchgeräusche</i>	<i>B8: reduzierte Thoraxbewegungen und keine Abdomenbewegung ohne Schnarchgeräusche</i>	<i>Event 3</i>
<i>A3: geringes Atemvolumen ohne Schnarchgeräusche</i>	<i>B9: reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	<i>Event 4</i>
<i>A4: großes Atemvolumen mit Schnarchgeräuschen</i>	<i>B6: starke Thorax- und Abdomenbewegungen</i>	<i>Event 5</i>
<i>A6: geringes Atemvolumen ohne Schnarchgeräusche</i>	<i>B4: gegenläufige Thorax- und Abdomenbewegungen</i>	<i>Event 6</i>

Tabelle 5: Sehr häufige Events

Successions in <i>AirflowUMX</i>	Successions in <i>ThoraxAbdomenUMX</i>	Events
<i>A5: reduziertes Atemvolumen ohne Schnarchgeräusche</i>	<i>B4: gegenläufige Thorax- und Abdomenbewegungen</i>	<i>Event 6</i>
<i>A5: reduziertes Atemvolumen ohne Schnarchgeräusche</i>	<i>B9: reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	<i>Event 4</i>
<i>A5: reduziertes Atemvolumen ohne Schnarchgeräusche</i>	<i>B0: Tacet</i>	<i>Event 6</i>
<i>A0: Tacet</i>	<i>B6: starke Thorax- und Abdomenbewegungen</i>	<i>Event 5</i>
<i>A1: reduziertes Atemvolumen mit Schnarchgeräuschen</i>	<i>B6: starke Thorax- und Abdomenbewegungen</i>	<i>Event 5</i>
<i>A1: reduziertes Atemvolumen mit Schnarchgeräuschen</i>	<i>B0: Tacet</i>	<i>Event 1</i>
<i>A2: kein Atemvolumen ohne Schnarchgeräusche</i>	<i>B9: reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	<i>Event 4</i>
<i>A2: kein Atemvolumen ohne Schnarchgeräusche</i>	<i>B0: Tacet</i>	<i>Event 2</i>
<i>A3: geringes Atemvolumen ohne Schnarchgeräusche</i>	<i>B0: Tacet</i>	<i>Event 4</i>
<i>A6: geringes Atemvolumen ohne Schnarchgeräusche</i>	<i>B9: reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	<i>Event 4</i>
<i>A0: Tacet</i>	<i>B9: reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	<i>Event 4</i>
<i>A5: reduziertes Atemvolumen ohne Schnarchgeräusche</i>	<i>B6: starke Thorax- und Abdomenbewegungen</i>	<i>EventTacet</i>

Tabelle 6: Weniger Häufige Events

Aus den Zwischenergebnissen der TWK werden für die Events TG-Regeln erzeugt (s. Kapitel 5.2.7). Die Namen der Events lassen sich z.B. aus den Namen der Successions in den TG-Regeln herleiten. Insgesamt werden 6 Events für die SBAS identifiziert, denen folgende bedeutungsvolle Namen gegeben werden:

Event 1: reduzierte Atmung mit Schnarchgeräuschen

Event 2: kein Atemvolumen und keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

Event 3: kein Atemvolumen und reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche

Event 4: kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

Event 5: starke Atmung mit Schnarchgeräuschen

Event 6: reduziertes Atemvolumen und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

Störungen in den Events werden, wie bei den Successions, nachträglich durch Filter beseitigt. Dabei werden sehr kurze Events in EventTacets überführt (s. Tabelle 7). Diese heuristischen Schwellwerte werden anhand von Histogrammen bestimmt (s. Anhang A.4).

Events	Dauer
Event 1	≤ 5 sec
Event 2	≤ 2 sec
Event 3	≤ 5 sec
Event 4	≤ 3 sec
Event 5	≤ 4 sec
Event 6	≤ 2 sec

Tabelle 7: Dauer von sehr kurzen Events

Letzendlich werden alle sehr kurzen Unterbrechungen in Events mit einer Dauer von weniger als 15 % der Gesamtdauer des Events als Störungen aufgefaßt und beseitigt.

5.2.5 Identifikation von Sequences in Eventfolgen

In diesem Schritt sollen Sequences in Eventfolgen erkannt werden. In Kapitel 3.3.5 wurde erläutert, daß stochastische Automaten zunächst einen Hinweis auf Sequences liefern können. Die Erkennung von Sequences erfolgt letztendlich durch die Bestimmung von Startevents und Endevents.

Zur Konstruktion eines stochastischen Automaten werden die relativen Übergangshäufigkeiten zwischen zwei aufeinanderfolgenden Events (s. Tabelle 8) wie folgt bestimmt:

$$\text{relative Übergangshäufigkeit} = \frac{\text{Anzahl der Events, die auf Event } X \text{ folgen}}{\text{Summe aller Übergänge}}$$

Es wird unterschieden zwischen direkt aufeinanderfolgenden Events und aufeinanderfolgenden Events, zwischen denen ein EventTacet vorkommt.

Eventübergänge	von Event 1	von Event 2	von Event 3	von Event 4	von Event 5	von Event 6
nach Event 1	0	0	0	0,01	0,034	0
nach Event 1 [über EventTacet]	0,01	0,01	0,01	0,01	0,034	0
nach Event 2	0	0	0,01	0,01	0	0
nach Event 2 [über EventTacet]	0	0	0	0	0,09	0
nach Event 3	0	0,079	0	0	0	0
nach Event 3 [über EventTacet]	0	0	0	0	0	0
nach Event 4	0	0	0	0	0,022	0,01

Tabelle 8: Relative Übergangshäufigkeiten zwischen Events.

Eventübergänge	von Event 1	von Event 2	von Event 3	von Event 4	von Event 5	von Event 6
nach Event 4 [über EventTacet]	0,0455	0	0	0,034	0,09	0,01
nach Event 5	0,01	0	0	0	0	0,034
nach Event 5 [über EventTacet]	0,023	0,057	0,057	0,09	0	0,057
nach Event 6	0,01	0	0	0	0	0
nach Event 6 [über EventTacet]	0,01	0	0	0,057	0,0455	0,01

Tabelle 8: Relative Übergangshäufigkeiten zwischen Events.

Ein stochastischer Automat besteht aus Zuständen, in diesem Fall *Event 1* bis *Event 6*, und Zustandsübergängen zwischen Events, die durch die relativen Übergangshäufigkeiten gekennzeichnet sind. Um eine übersichtliche Darstellung des Automaten zu gewinnen, wird anhand eines Histogramms für die relativen Übergangshäufigkeiten aus Tabelle 8 zwischen *seltene*, *häufigen* und *sehr häufigen* Übergängen unterschieden (s. Abb.31). Aus den *häufigen* und *sehr häufigen* Übergängen wird ein Automat konstruiert (s. Abb.32). Andere Übergänge werden nicht weiter betrachtet.

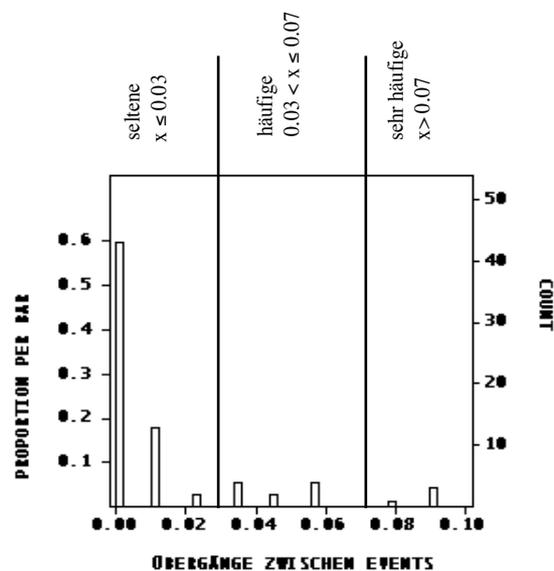


Abb.31: Histogramm für die relativen Übergangshäufigkeiten zwischen Events (mit und ohne EventTacet)

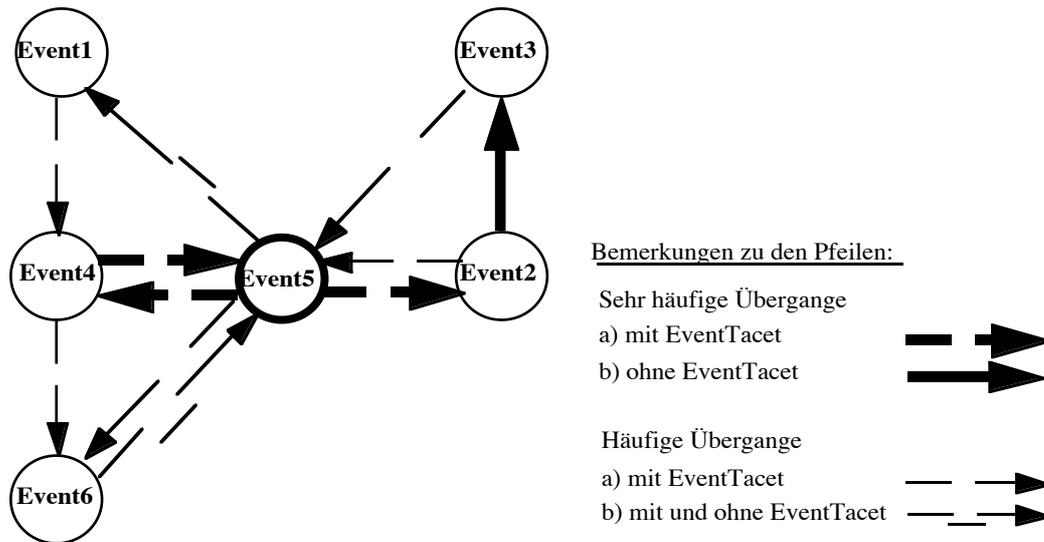


Abb.32: Automat mit Events und Übergängen zwischen Events

In Abb.32 entsprechen Events den Zuständen des Automaten und Pfeile den *sehr häufigen* bzw. *häufigen* Übergängen zwischen zwei Events. Es wird zwischen Übergängen *mit*, *ohne* oder *mit und ohne* Tacets unterschieden. *Event5* wird als ein besonderes Event identifiziert, da zu diesem Event die meisten Pfeile hinführen bzw. wegführen. Dies bedeutet, daß Sequences vermutlich mit *Event5* starten oder enden. Folgende Zyklen im Automaten liefern Hinweise auf Sequences:

- (*Event 5* \Rightarrow) *Event 4* \Rightarrow *Event 5*
- (*Event 5* \Rightarrow) *Event 2* \Rightarrow *Event 3* \Rightarrow *Event 5*
- (*Event 5* \Rightarrow) *Event 1* \Rightarrow *Event 4* \Rightarrow *Event 5*
- (*Event 5* \Rightarrow) *Event 4* \Rightarrow *Event 6* \Rightarrow *Event 5*
- (*Event 5* \Rightarrow) *Event 6* \Rightarrow *Event 5*

Das in dieser Arbeit eingesetzte Verfahren zur Erkennung von Sequences geht von Startevents und Endevents aus. Zur Identifikation von Startevents und Endevents werden länger andauernde EventTacets bestimmt (s. Abb.33). Anschließend wird die prozentuale Anzahl aller Events vor bzw. nach einem längeren EventTacet berechnet (s. Abb.34). Events werden als mögliche Startevents bzw. Endevents bezeichnet, falls vor bzw. nach einem Event häufig ein länger andauerndes EventTacet auftritt.

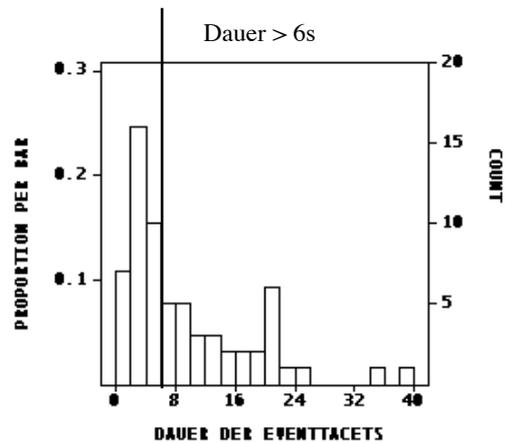


Abb.33: Histogramm für die Dauer aller EventTacets

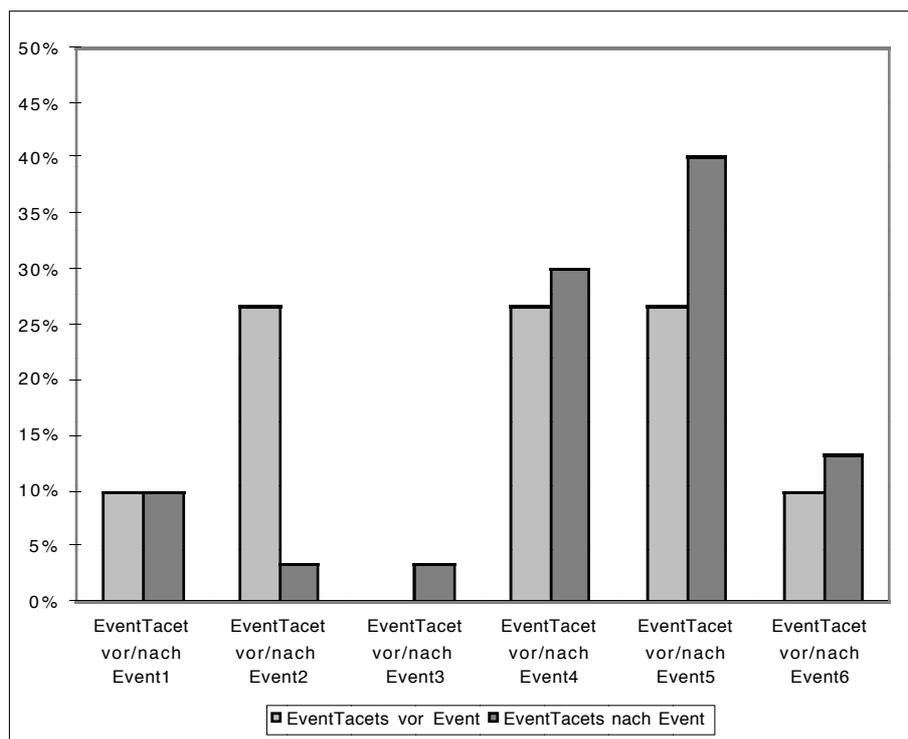
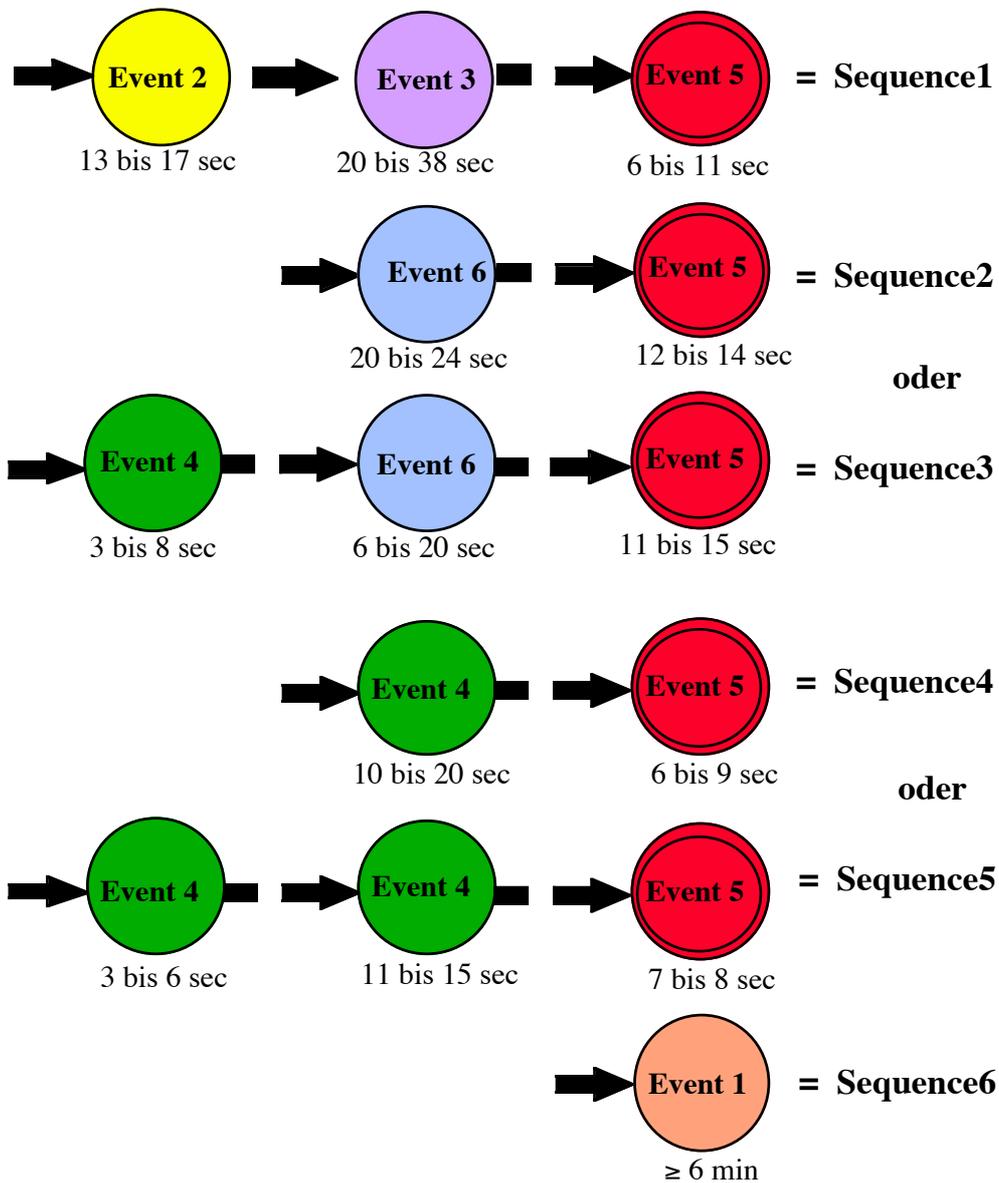


Abb.34: Prozentuale Anzahl von Events vor bzw. nach einem länger andauernden EventTacet

Als besonderes Event hat sich *Event5: großes Atemvolumen und starke Thorax- und Abdomenbewegungen mit Schnarchgeräuschen* ausgezeichnet, das hier als Endevent identifiziert wird. Alle anderen Events können Startevents sein, mit

Ausnahme von *Event3*. Durch Zerlegung der Eventfolge in Teilfolgen, die mit *Event5* enden, wurden folgende Sequences identifiziert (s.u.). *Sequence6* besteht ausschließlich aus *Event1* und unterscheidet sich daher stark von allen anderen Sequences.



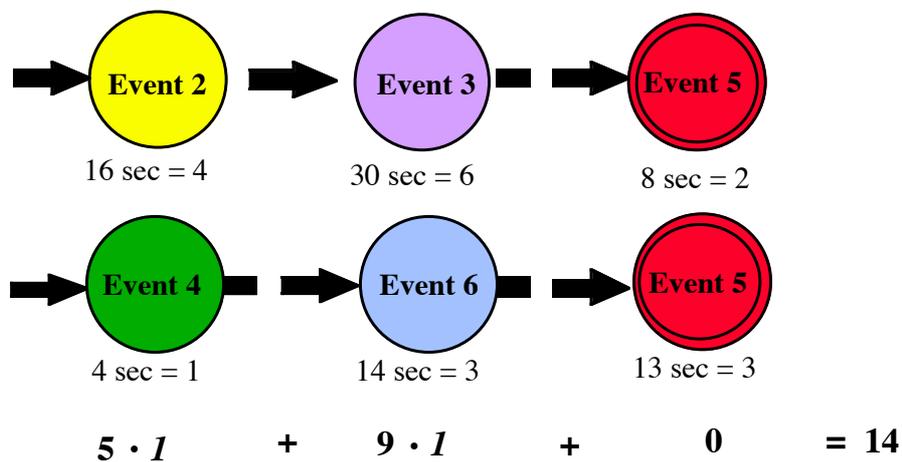
5.2.6 Zusammenfassung von ähnlichen Sequences zu TemporalPatterns

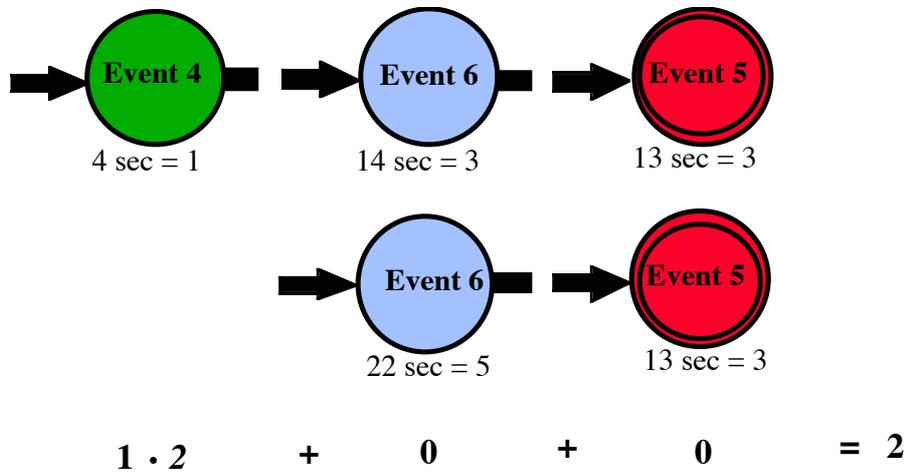
In diesem Schritt werden ähnliche Sequences zu TemporalPatterns zusammengefaßt. Dabei wird die Ähnlichkeit zwischen Sequences durch Stringaustauschalgorithmus festgestellt. Es werden Abstände zwischen Sequences berechnet, die hier als Strings aufgefaßt werden. Events entsprechen dann einzelnen Zeichen in einem String. Folgende Operationen werden angewendet, die wie folgt gewichtet werden:

1. Einfügen eines Zeichens = 2
2. Entfernen eines Zeichens = 2
3. Umkehren von zwei Zeichen = 3
4. Ersetzen eines Zeichens = 1

Bei den Sequences handelt es sich um Strings, bei denen jedes Zeichen (Event) eine bestimmte Dauer besitzt. Daher wird zusätzlich die Dauer der Events in die Gewichtung einbezogen, wobei alle 5 sec das Gewicht um eins erhöht wird.

Beispiel 1:



Beispiel 2:

Die berechneten Abstände für alle Sequences werden im folgenden in eine Tabelle eingetragen.

Abstände zwischen den Sequences	Sequence 1	Sequence 2	Sequence 3	Sequence 4	Sequence 5	Sequence 6
Sequence 1		14	17	14	16	>20
Sequence 2			2	6	9	>20
Sequence 3				8	6	>20
Sequence 4					2	>20
Sequence 5						>20
Sequence 6						

Tabelle 9: Ähnlichkeitstabelle für Sequences

Aus der Ähnlichkeitstabelle ergibt sich, daß *Sequence1* und *Sequence6* sehr unterschiedlich zu allen anderen Sequences sind. *Sequence2* und *Sequence3* sowie *Sequence4* und *Sequence5* sind jeweils sehr ähnlich zueinander und können damit jeweils zu einem TemporalPattern zusammengefaßt werden. Insgesamt werden dadurch vier TemporalPatterns erkannt:

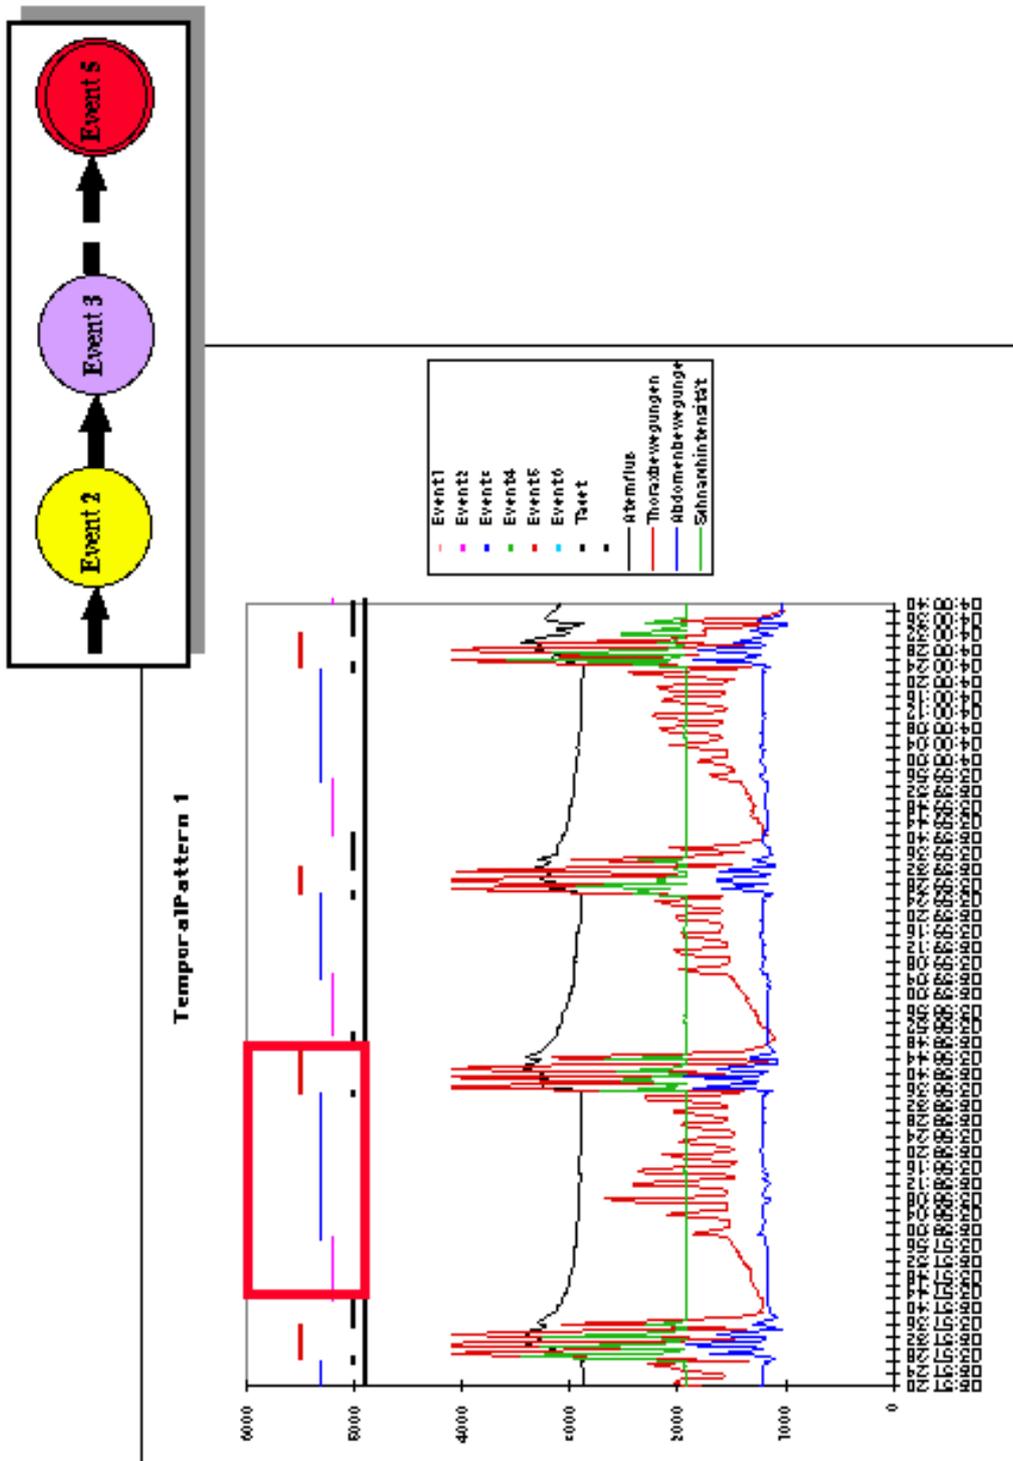


Abb.35: TemporalPattern1 mit den Events und den Zeitreihen *Atemfluß*, *Thorax- und Abdomenbewegungen* und *Schnarchintensität*.

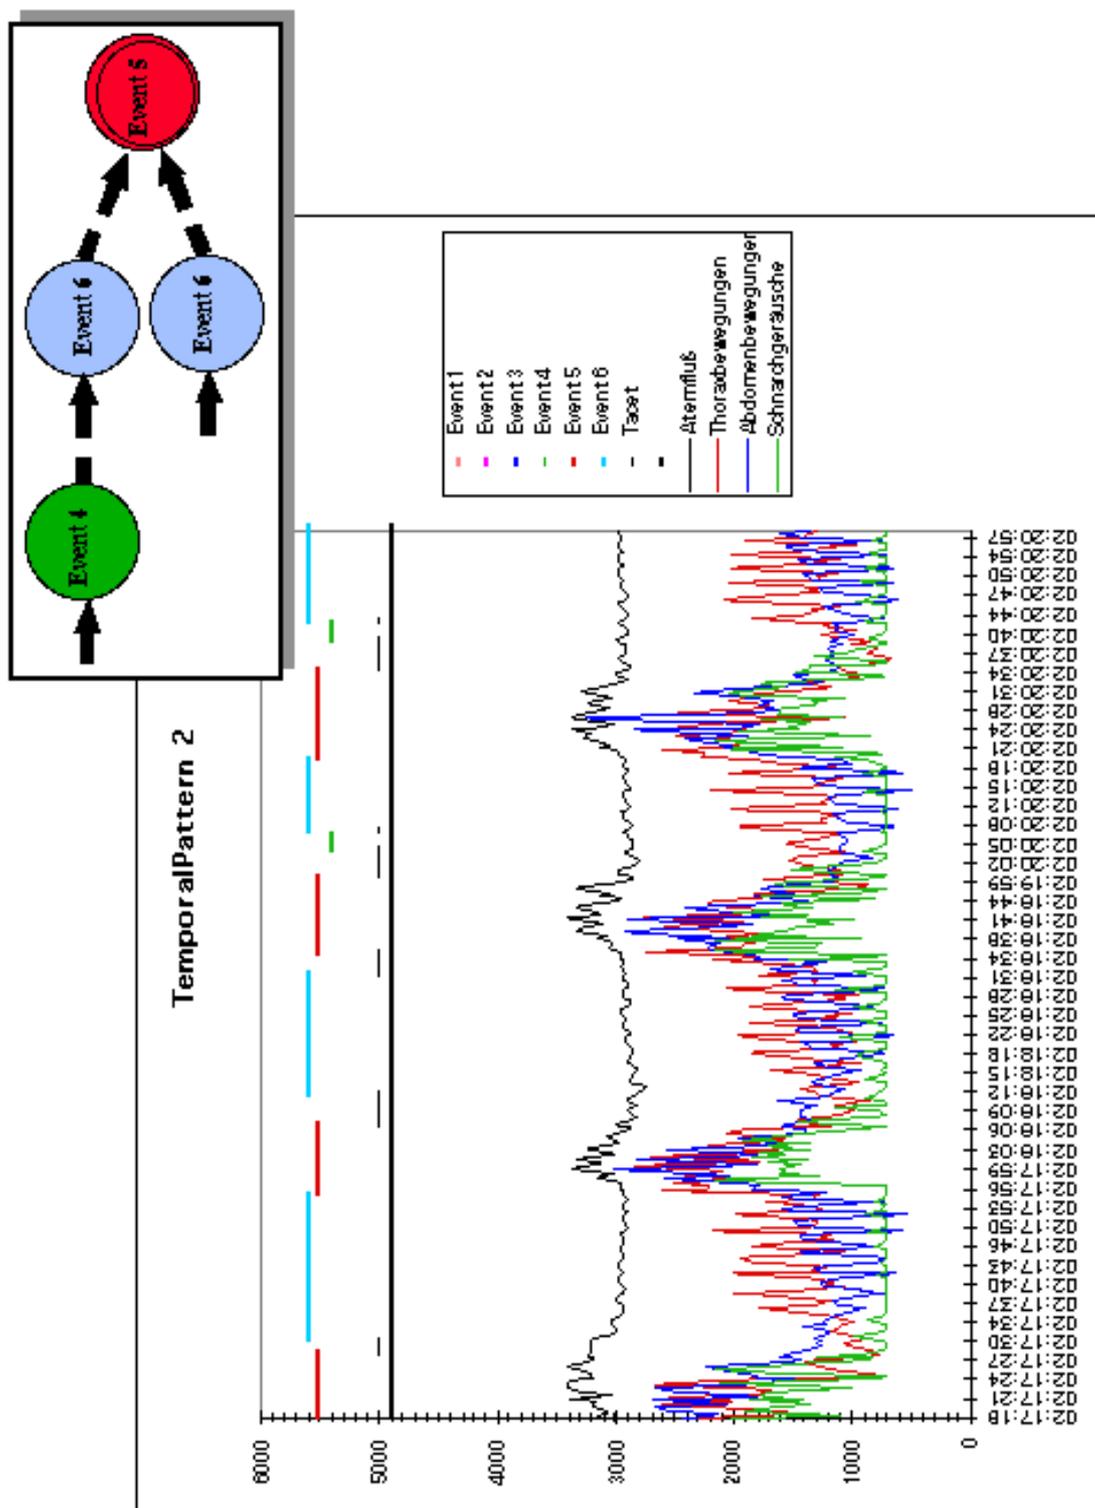


Abb.36: TemporalPattern2 mit den Events und den Zeitreihen *Atemfluß*, *Thorax- und Abdomenbewegungen* und *Schnarchintensität*.

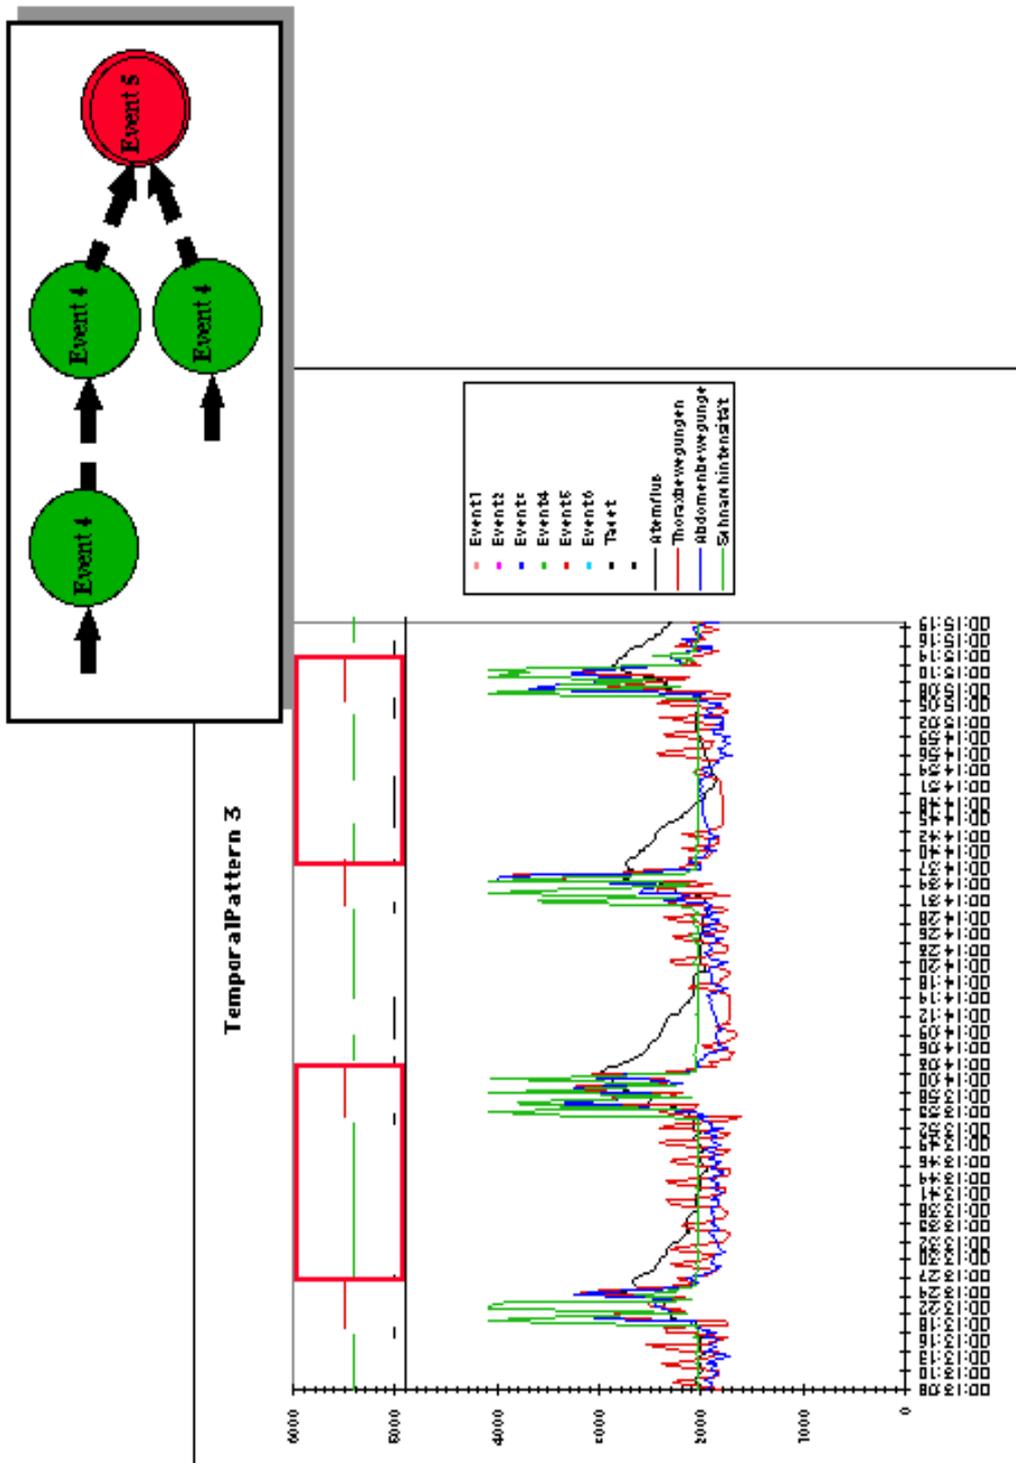


Abb.37: TemporalPattern3 mit den Events und den Zeitreihen *Atemfluß*, *Thorax- und Abdomenbewegungen* und *Schnarchintensität*.

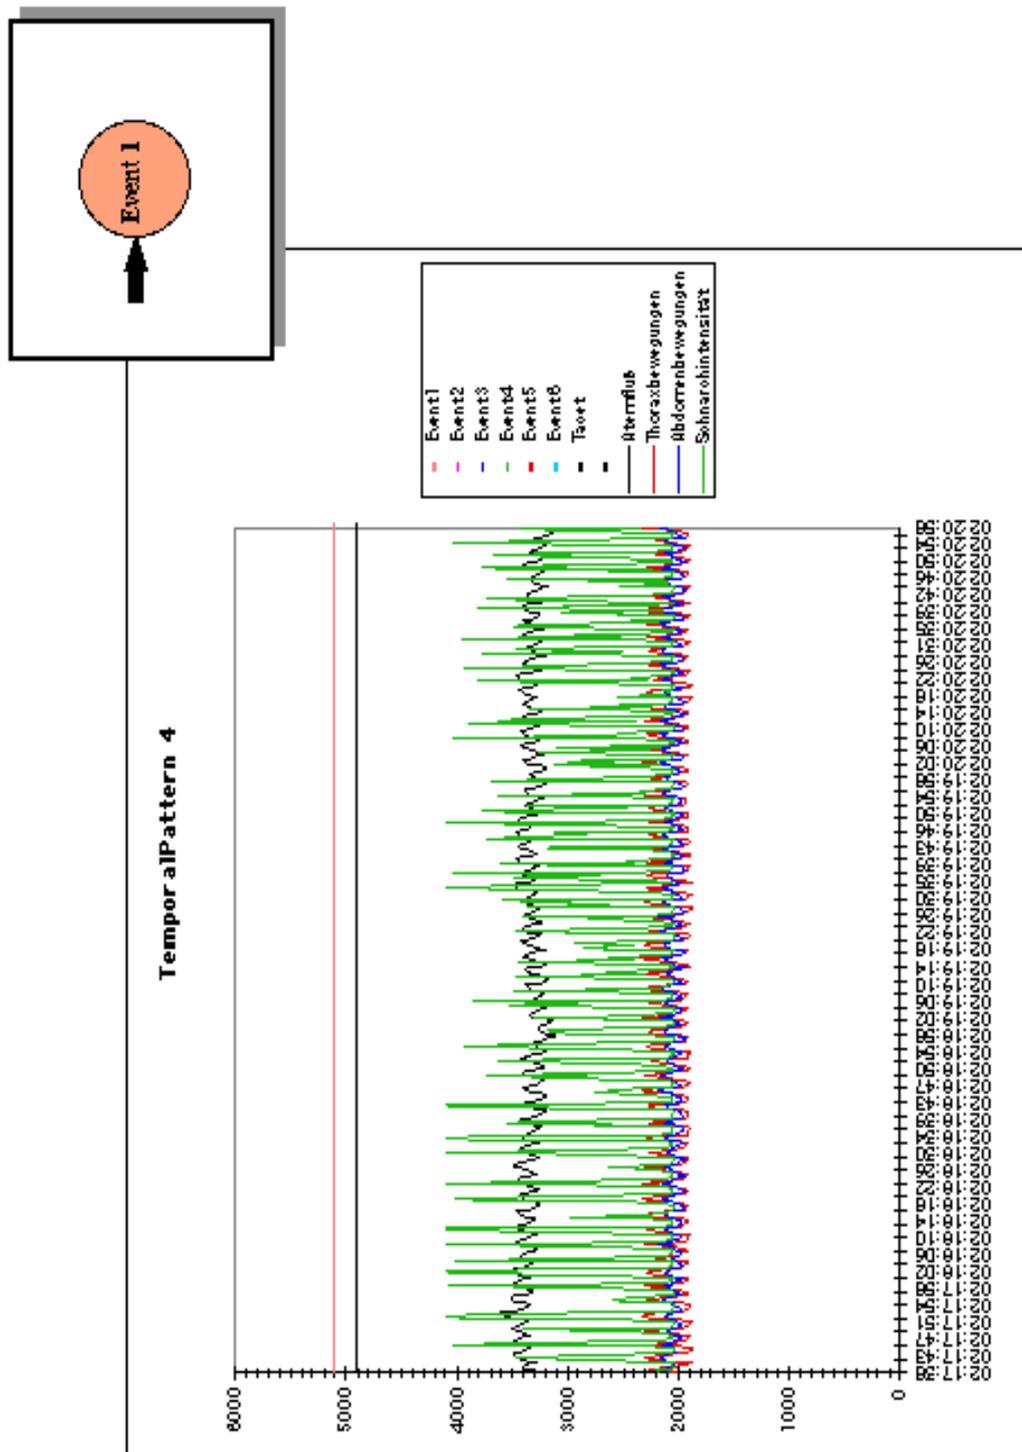


Abb.38: TemporalPattern4 mit den Events und den Zeitreihen *Atemfluß*, *Thorax- und Abdomenbewegungen* und *Schnarchintensität*.

5.2.7 Eine temporale Grammatik (TG) für SBAS

In diesem Schritt werden Events, Sequences und TemporalPatterns für SBAS durch TG-Regeln in eine für Menschen verständliche, sprachliche Beschreibung überführt (s. Kapitel 3.4).

Events werden unabhängig von den TemporalPatterns beschrieben. Das bedeutet, daß für alle TemporalPatterns eine bestimmte Anzahl von Events existiert, wobei dieselben Events auch in verschiedenen TemporalPatterns auftreten können. Ein Beispiel hierfür ist *Event5*, das in fast allen TemporalPatterns vorkommt. In den TG-Regeln für die Events wird das Sprachkonstrukt **‘ist ungefähr gleichzeitig mit’** verwendet, durch das ungefähr gleichzeitige Successions sprachlich beschrieben werden. Durch die TWK wird zwischen unterschiedlich häufigen Events unterschieden (s. Tabelle 5 und Tabelle 6). Weniger häufige Events werden den sehr häufigen Events zugeordnet. Alternativen zwischen ähnlichen Successions werden durch das Sprachkonstrukt **‘oder’** beschrieben. Da es sich bei Successions um Terminalzeichen handelt, werden diese unterstrichen. Eine regelhafte Beschreibung von PrimitivePatterns, aus denen die Successions bestehen, ist durch die sig*-Regeln gegeben (s. Anhang A.6). Jedem Event wird ein für die Anwendung ggf. bedeutsamer Name gegeben, der aus den Namen der im Event auftretenden Successions hergeleitet wird.

Für jede Sequence wird eine Regel erzeugt, die eine temporale Beschreibung der zeitlich aufeinanderfolgenden Events der Sequence enthält. Zur Beschreibung von direkt aufeinanderfolgenden Events wird das Sprachkonstrukt **‘gefolgt von’** verwendet. Folgt ein Event einem anderen Event nach einem EventTacet, so wird das Sprachkonstrukt **‘gefolgt nach [‘ Dauer des EventTacet’s] von’** verwendet. Für jedes Event bzw. EventTacet in einer TG-Regel wird eine minimale und eine maximale Dauer des Event bzw. des EventTacet angegeben.

TemporalPatterns bestehen aus Alternativen zwischen Sequences, die durch das Sprachkonstrukt **‘oder’** in den TG-Regeln beschrieben werden.

Den Sequences und den TemporalPatterns werden keine bedeutsamen Namen gegeben, da die Namen zu komplex wären. Den Sequences und den TemporalPatterns soll später, falls möglich, bei einer Expertenbefragung ein Name aus der Anwendung gegeben werden (s. Kapitel 5.3.3).

TG-Regeln für Events der SBAS**Ein Event ist ein**

Event 1: reduzierte Atmung mit Schnarchgeräuschen

falls

(reduziertes Atemvolumen mit Schnarchgeräuschen

oder

Tacet)

ist ungefähr gleichzeitig mit

reduzierte parallele Thorax- und Abdomenbewegungen mit Schnarchgeräuschen

Ein Event ist ein

Event 2: kein Atemvolumen und keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche,

falls

kein Atemvolumen ohne Schnarchgeräusche

ist ungefähr gleichzeitig mit

(keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

oder

Tacet)

Ein Event ist ein

Event 3: kein Atemvolumen und reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche

falls

kein Atemvolumen ohne Schnarchgeräusche

ist ungefähr gleichzeitig mit

reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche

Ein Event ist ein

Event 4: kein bis reduziertes Atemvolumen und reduzierte parallele und phasenverschobene Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

falls

(

(geringes Atemvolumen ohne Schnarchgeräusche

oder

Tacet

oder

reduziertes Atemvolumen ohne Schnarchgeräusche

oder

kein Atemvolumen ohne Schnarchgeräusche)

ist ungefähr gleichzeitig mit

reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen

)

oder

(

geringes Atemvolumen ohne Schnarchgeräusche

ist ungefähr gleichzeitig mit

Tacet

)

Ein Event ist ein

Event 5: starke Atmung mit Schnarchgeräuschen

falls

(großes Atemvolumen mit Schnarchgeräuschen

oder

Tacet

oder

reduziertes Atemvolumen mit Schnarchgeräusche)

ist ungefähr gleichzeitig mit

starke Thorax- und Abdomenbewegungen

Ein Event ist ein

Event 6: reduziertes Atemvolumen mit phasenverschobenen Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

falls

(

(geringes Atemvolumen ohne Schnarchgeräusche

oder

reduziertes Atemvolumen ohne Schnarchgeräusche)

ist ungefähr gleichzeitig mit

phasenverschobene Thorax- und Abdomenbewegungen

)

oder

(

(reduziertes Atemvolumen ohne Schnarchgeräusche

ist ungefähr gleichzeitig mit

Tacet)

)

TG-Regeln für Sequences der SBAS**Eine Sequence ist eine**

Sequence1 [40 sec, 64 sec]

falls

Event 2: kein Atemvolumen und keine Thorax und Abdomenbewegungen ohne Schnarchgeräusche [13 sec, 18 sec]

gefolgt von

Event 3: kein Atemvolumen und reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche [20 sec, 39 sec]

gefolgt nach [0.5 sec, 5 sec] von

Event 5: starke Atmung mit Schnarchgeräuschen [6 sec, 12 sec]

Eine Sequence ist eine

Sequence2 [36 sec, 37 sec]

falls

Event 6: reduziertes Atemvolumen und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche [20 sec, 25 sec]

gefolgt nach [0 sec, 4 sec] **von**

Event 5 - starke Atmung mit Schnarchgeräuschen [11 sec, 15 sec]

Eine Sequence ist eine

Sequence3 [19 sec, 35 sec]

falls

Event 4 - kein bis reduziertes Atemvolumen mit reduzierten parallelen und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche [2 sec, 8 sec]

gefolgt nach [0 sec, 8 sec] **von**

Event 6 - kein bis reduziertes Atemvolumen und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche [3 sec, 21 sec]

gefolgt nach [0 sec, 5 sec] **von**

Event 5 - starke Atmung mit Schnarchgeräuschen [11 sec, 16 sec]

Eine Sequence ist eine

Sequence4 [27 sec, 28 sec]:

falls

Event 4 - kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche [2 sec, 27 sec]

gefolgt nach [1 sec, 20 sec] **von**

Event 5 - starke Atmung mit Schnarchgeräuschen
[3 sec, 9 sec]

Eine Sequence ist eine*Sequence5* [18 sec, 30 sec]**falls***(Event 4 - kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche*
[3 sec, 6 sec]**gefolgt nach** [0 sec, 8 sec] **von***Event 4 - kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche*
[10 sec, 22 sec])**gefolgt nach** [1 sec, 20 sec] **von***Event 5 - starke Atmung mit Schnarchgeräuschen*
[3 sec, 9 sec].**Eine Sequence ist eine***Sequence6* [6 min]**falls***Event1 - reduzierte Atmung mit Schnarchgeräuschen* [6 min]**TG-Regeln für TemporalPatterns der SBAS****Ein TemporalPattern ist ein***TemporalPattern1* [40 sec, 64 sec]**falls***Sequence1* [40 sec, 64 sec]**Ein TemporalPattern ist ein***TemporalPattern2* [19 sec, 37 sec]**falls***Sequence2* [36 sec, 37 sec]**oder***Sequence3* [19 sec, 35 sec]

Ein TemporalPattern ist ein

TemporalPattern3 [18 sec, 30 sec]

falls

Sequence4 [27 sec, 28 sec]

oder

Sequence5 [18 sec, 30 sec]

Ein TemporalPattern ist ein

TemporalPattern4 [6 min]

falls

Sequence6 [6 min]

5.3 Evaluation der Ergebnisse der TWK angewandt auf SBAS

In Kapitel 5.3.1 wird die Vorgehensweise bei der Evaluation der Ergebnisse der TWK angewandt auf SBAS vorgestellt. Dabei wird eine qualitative Evaluation der Ergebnissen der TWK durch eine Expertenbefragung vorgeschlagen. In Kapitel 5.3.2 wird ein Fragebogen zur qualitativen Evaluation vorgestellt. Kapitel 5.3.3 enthält dann die Ergebnisse der Befragung.

5.3.1 Vorgehensweise bei der Evaluation der Ergebnisse der TWK

Die durch die TWK entdeckten komplexen Muster von SBAS (TemporalPatterns) werden explorativ gewonnen. Daher ist eine Evaluation der TemporalPatterns und deren sprachliche Beschreibung anhand von TG-Regeln erforderlich. Es wird dabei überprüft, ob die TemporalPatterns richtig erkannt worden sind und die Beschreibungen der TemporalPatterns durch die TG-Regeln für die Anwendung einen Sinn machen. Da es sich um eine explorative Methode handelt, ist auch zu überprüfen, ob durch die TWK "neues" Wissen in den Mustern von SBAS entdeckt worden ist.

Da die mit Hilfe der Schritte der TWK erzeugten TG-Regeln als eine Wissensbasis (WB) aufgefaßt werden können, werden zuerst bereits vorhandene Vorgehensweisen für die Evaluation von WB betrachtet. Die Evaluation von WB wird als ein wesentlicher Aspekt für die Akzeptanz von wissensbasierten Systemen (WBS) aufgefaßt [Puppe 91, Miller/Sittig 90]. Das Wissen sollte verständlich, vollständig und einfach kommunizierbar sein, da Experten entscheiden können müssen, wann und wie Wissen in einem WBS modifiziert und an neue Bedürfnisse angepaßt werden sollte [Nykänen et al. 91]. Durch den MEDWIS-Arbeitskreis "Evaluation" wurde ein Leitfaden zur Evaluation von WB entwickelt, durch den die bereits existierenden Vorgehensweisen für die Evaluation von WB wie folgt zusammenfaßt werden [Ohmann/Belenky 96]:

1. Das gesamte Vorgehen bei der Evaluationsstudie muß in einem *Protokoll* festgehalten werden.
2. Es muß ein *Vergleich* mit einem Referenzwert, z.B. dem bestehenden System in Labor oder Klinik, durchgeführt werden.
3. Die Evaluierung der WB erfolgt in mehreren *Phasen*:

- 3.1 Qualitative Evaluation der WB: Verifizierung der WB durch eine strukturelle und semantische Überprüfung der Regeln.
 - 3.2 Validierung der WB: Überprüfung der Richtigkeit und Zuverlässigkeit des in der WB enthaltenen Wissens, insbesondere was die Diagnose-sicherheit des WBS angeht.
 - 3.3 Beurteilung von Funktionalität und Benutzerfreundlichkeit.
 - 3.4 Beurteilung des klinischen Nutzens.
4. Der Evaluierungsprozeß muß verschiedene *Evaluierer*, wie Systementwickler, Experten und Benutzer, einbeziehen.
 5. Die Evaluierung sollte verschiedene *Testumgebungen* wie logische Testung, Laborstudie und Feldstudie umfassen.

Im Rahmen dieser Arbeit wird vorgeschlagen, eine qualitative Evaluation durch eine Expertenbefragung durchzuführen. Die mit Hilfe der TWK erzeugten TG-Regeln bilden eine Grundlage für ein Gespräch mit einem Experten der Anwendung. Da den Successions und damit auch den Events ein für die Anwendung ggf. bedeutsamen Namen gegeben worden ist (s. Kapitel 5.2), kann eine Interpretation der Ergebnisse durch einen Experten der Anwendung vollständig auf einer symbolischen, sprachlichen Ebene erfolgen. Dies bedeutet, daß durch die TG-Regeln die Ergebnisse der TWK für einen Experten der Anwendung verständlich und nachvollziehbar sind. Gleichzeitig kann eine visuelle Überprüfung der Ergebnisse der TWK durch eine graphische Darstellung der Ergebnisse durchgeführt werden. Anhand eines Beispiels wird im folgenden erklärt, welche Ergebnisse für eine qualitative Evaluation durch Expertenbefragung verwendet werden können.

Beispiel:

Von einem Patienten mit schlafbezogenen Atmungsstörungen (SBAS) werden in einer Nacht fünf Größen aufgenommen: *Atemfluß*, *Thoraxbewegungen*, *Abdomenbewegungen*, *Schnarchgeräusche* und *Sauerstoffsättigung*. Ziel ist es, in den Zeitreihen komplexe Muster zu entdecken, die vermutlich einem oder mehreren Krankheitsbildern entsprechen.

Die durch eine Strukturanalyse entdeckten PrimitivePatterns sind das erste zu beurteilende Ergebnis der TWK. Durch Generierung von sig*-Regeln für die PrimitivePatterns kann die Bedeutung eines PrimitivePattern für die Anwendung anhand der Regeln überprüft werden. Da durch die sig*-Regeln die PrimitivePatterns durch ihre signifikanten Merkmale beschrieben werden, kann jedem PrimitivePattern ein bedeutungsvoller Name gegeben werden, der aus den Merkmalen der sig*-Regel abgeleitet wird. Dies ist von großer Bedeutung, da nun mit ggf. für

die Anwendung bedeutsamen Namen weitergearbeitet werden kann.

sig*- Regel am Beispiel von *PrimitivePattern (2)*:

Ein PrimitivePattern ist ein

A2

falls

und *Atemvolumen-kein* \in [0.95, 1]

und *Atemvolumen-reduziert* = 0

und

Schnarchintensität \in [-0.04, 0.24]

Zur Gewinnung eines Namens für das PrimitivePattern *A2* werden die Merkmale folgendermaßen interpretiert: *Atemvolumen-kein* \in [0.95, 1] bedeutet, daß höchst wahrscheinlich kein Atemvolumen auftritt und *Schnarchintensität* \in [0.04, 0.24] bedeutet, daß keine oder sehr wenige Schnarchgeräusche vorkommen. Die Merkmale *Atemvolumen-kein* und *Atemvolumen-reduziert* sind redundant, so daß das Merkmal *Atemvolumen-reduziert* für die Namensgebung nicht berücksichtigt wird. PrimitivePattern *A2* wird daher der Name *kein Atemvolumen ohne Schnarchgeräusche* gegeben.

Im nächsten Schritt der TWK werden unmittelbar aufeinanderfolgende Primitive-Patterns zu Successions zusammengefaßt (s. Kapitel 3.3.3). Ziel ist es, ungefähr gleichzeitige Successions zu erkennen, die dann zu Events zusammengefaßt werden (s. Kapitel 3.3.4). In dem Beispiel werden die beiden Events *Event4* und *Event5* identifiziert. Diese sind das nächste zu beurteilende Ergebnis der TWK. Hierzu werden TG-Regeln erzeugt, durch die ungefähr gleichzeitig auftretende Alternativen von Successions beschrieben werden.

TG-Regel am Beispiel von *Event5*:

Ein Event ist ein

Event 5

falls

(*großes Atemvolumen*

oder

reduziertes Atemvolumen mit Schnarchgeräuschen)

ist ungefähr gleichzeitig mit

starke Thorax- und Abdomenbewegungen

Die Herleitung eines bedeutungsvollen Namen für Events erfolgt durch eine Interpretation der ungefähr gleichzeitig auftretende Alternativen von Successions in den Events. Selten auftretende ungefähr gleichzeitigen Successions bleiben dabei unberücksichtigt (s. Anhang A.7). Da in *Event5* hauptsächlich die Successions *großes Atemvolumen* und *starke Thorax- und Abdomenbewegungen* ungefähr gleichzeitig auftreten (s. Tabelle 5), wird *Event5* der Name *großes Atemvolumen und starke Thorax- und Abdomenbewegungen* gegeben. *Event4* erhält den Namen *kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche*.

Anhand von TG-Regeln kann eine inhaltliche Überprüfung des Events erfolgen. Z.B. wird bei *Event5* überprüft, ob die im Event auftretenden Successions *großes Atemvolumen* und *starke Thorax- und Abdomenbewegungen* tatsächlich ungefähr gleichzeitig auftreten dürfen. Gleichzeitig kann eine visuelle Überprüfung der Events erfolgen (s. Abb.40).

Sequences und TemporalPatterns sind die als letztes zu beurteilenden Ergebnisse der TWK. Im folgenden Beispiel treten zwei Sequences auf, die zu einem TemporalPattern zusammengefaßt werden (s. Abb.39).

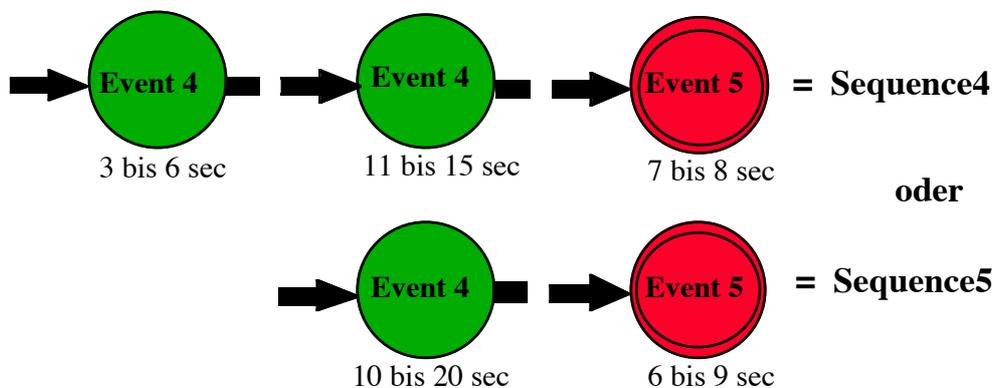


Abb.39: Beispiel für eine graphische Darstellung der Sequences von TemporalPattern3

Zur Überprüfung der Sequences werden aus den Ergebnissen der TWK TG-Regeln erzeugt. Durch TG-Regeln für die Sequences werden komplexe Muster in multivariaten Zeitreihen als eine zeitliche Abfolge von Events auf einer symbolischen, sprachlichen Ebene beschrieben. Hierzu werden die Sprachkonstrukte, 'gefolgt von' oder 'gefolgt nach [‘Dauer des EventTacets ’] von' verwendet. Außerdem existiert für jedes Event ein bedeutungsvoller Name, der in den TG-

Regeln eingesetzt wird. Gleichzeitig kann eine visuelle Überprüfung der Sequences eines TemporalPattern erfolgen (s. Abb.40).

TG-Regel am Beispiel von Sequence5:

Eine Sequence ist eine

Sequence5 [18 sec, 30 sec]

falls

(Event 4 - kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche
[3 sec, 6 sec]

gefolgt nach [0 sec, 8 sec] **von**

Event 4 - kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche
[10 sec, 22 sec])

gefolgt nach [1 sec, 20 sec] **von**

Event 5 - starke Atmung mit Schnarchgeräuschen
[3 sec, 9 sec].

In diesem Beispiel wird durch eine TG-Regel die zeitliche Abfolge von zwei *Event4* und *Event5* sprachlich beschrieben. Dabei existieren zwei EventFacets zwischen den Events. Jedes Event besitzt eine minimale und eine maximale Dauer. Z.B. darf das zweite *Event4* nicht kürzer als 10 sec und nicht länger als 22 sec sein. Dasselbe gilt für *Sequence5* mit einer Gesamtdauer von 18 sec bis zu 30sec. Durch diese Angaben kann der Gültigkeitsbereich der Dauer der Events und der Sequence durch einen Experten überprüft werden.

Die TG-Regel für *TemporalPattern3* besagt, daß *Sequence4* und *Sequence5* ähnlich sind und daher zu einem TemporalPattern zusammengefaßt werden können. Durch diese TG-Regel kann der Wertebereich für die Dauer des TemporalPattern durch einen Experten überprüft werden.

TG-Regel am Beispiel von TemporalPattern3:

Ein TemporalPattern ist ein

TemporalPattern3 [18 sec, 30 sec]

falls

SequenceA [18 sec, 30 sec]

oder

SequenceB [27 sec, 28 sec].

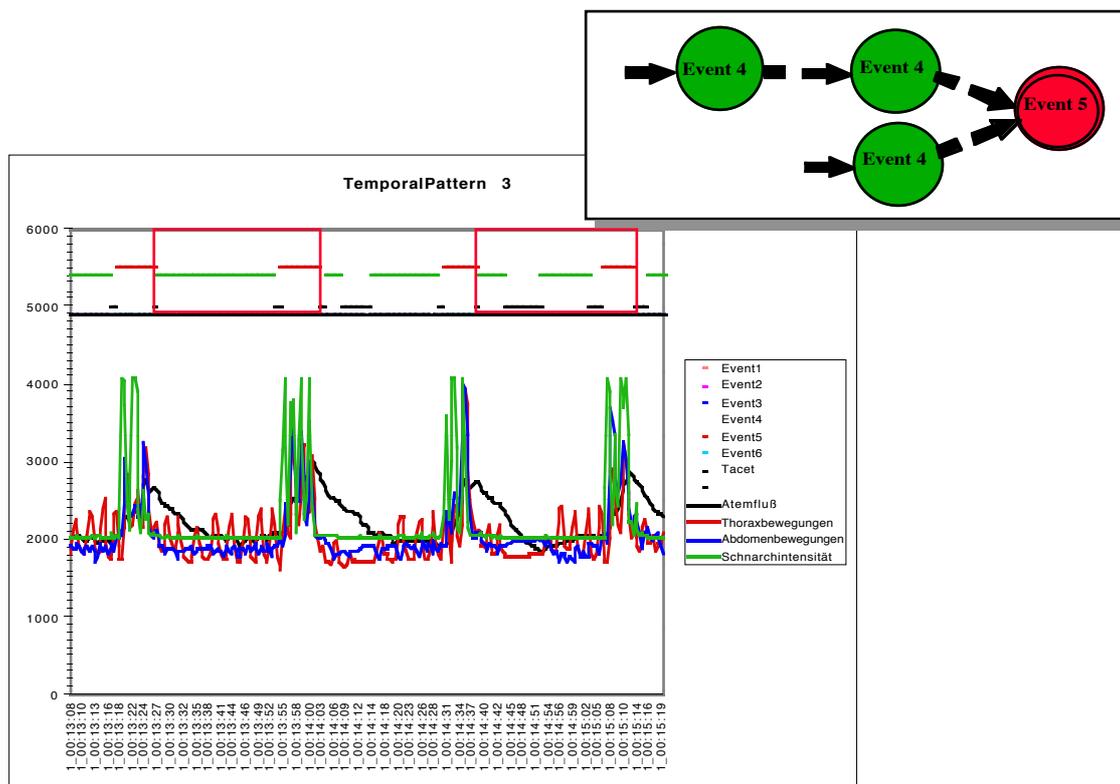


Abb.40: Beispiel für eine graphische Darstellung der Events und EventTacets eines TemporalPatterns zusammen mit der multivariaten Zeitreihe

Im folgenden werden die wesentlichen Ergebnisse der TWK zusammengefaßt dargestellt, anhand derer die Methode überprüft werden kann:

1. sig*- Regeln zur Beschreibung von PrimitivePatterns
2. Ggf. für die Anwendung sinnvolle Namen für PrimitivePatterns bzw. Successions, die aus sig*-Regeln abgeleitet werden
3. TG-Regeln für Events in Sequences
4. Ggf. für die Anwendung sinnvolle Namen für Events
5. TG-Regeln für Sequences von TemporalPatterns
6. TG-Regeln für TemporalPatterns
7. graphische Darstellung von Sequences und TemporalPatterns
8. Graphiken mit Events und EventTacets von TemporalPatterns zusammen mit den multivariaten Zeitreihen

5.3.2 Eine Methode zur qualitativen Evaluation der Ergebnisse

In dieser Arbeit wird vorgeschlagen, eine Evaluation der Ergebnisse durch eine Expertenbefragung durchzuführen. Um eine strukturierte Expertenbefragung durchführen zu können, wurde zur Befragung des Experten ein Fragebogen erstellt.

Bisherige Fragebögen zur Evaluation von WB und WBS beschränken sich hauptsächlich auf zwei Bereiche. Zum einen werden Fragebögen zur Evaluierung der Anwenderzufriedenheit erstellt, insbesondere was die Effektivität, Effizienz und Benutzerfreundlichkeit bei der Interaktion zwischen System und Benutzer betrifft [Ohmann/Belenky 96]. Diese Fragebögen können hier nicht verwendet werden. Zum anderen existieren Fragebögen zur Wissensakquisition. Hier werden Interviewtechniken entwickelt, die das Wissen des Experten erheben sollen [Balzer et al. 92]. Im Rahmen dieser Arbeit erfolgt die Wissensakquisition nicht durch eine Expertenbefragung, sondern das Wissen wird explorativ durch die TWK gewonnen, so daß diese Fragebögen nicht verwendet werden können. Aus den genannten Gründen wurde für die qualitative Evaluation der TG und der Ergebnisse der TWK ein eigener Fragebogen entworfen.

Zur Expertenbefragung wird eine strukturierte Vorgehensweise vorgeschlagen. Dabei wird zunächst der Experte aufgefordert, die entdeckten TemporalPatterns zu beschreiben. Hierzu werden dem Experten Graphiken mit den TemporalPatterns und der multivariaten Zeitreihe vorgelegt (s. Beispiel in Abb.40). Die Beschreibungen des Experten werden dabei auf Band aufgenommen. Diese können später mit dem mit Hilfe der TWK gewonnen regelhaften Wissen verglichen werden. Dadurch kann eine unabhängige Evaluation der Ergebnisse durchgeführt werden, wobei die Beschreibung von TemporalPatterns durch die TWK mit der Beschreibung von TemporalPatterns durch einen Experten der Anwendung verglichen wird

Obwohl bei einer Expertenbefragung zwischen den verschiedenen Abstraktionsebenen gewechselt werden kann (s. Abb.41), wird durch den Fragebogen eine systematische Vorgehensweise vorgeschlagen. Das heißt, daß zunächst Fragen zu TemporalPatterns und Sequences gestellt werden, und erst danach Fragen zu Events gestellt werden. Falls erforderlich, werden im Anschluß oder auch während der Befragung PrimitivePatterns anhand der sig*-Regeln überprüft. Durch diese strukturierte Vorgehensweise wird zuerst allgemeines Wissen über die komplexen Muster in multivariaten Zeitreihen erfragt. Erst danach wird auf den unte-

ren Abstraktionsebenen Detailwissen erfragt.

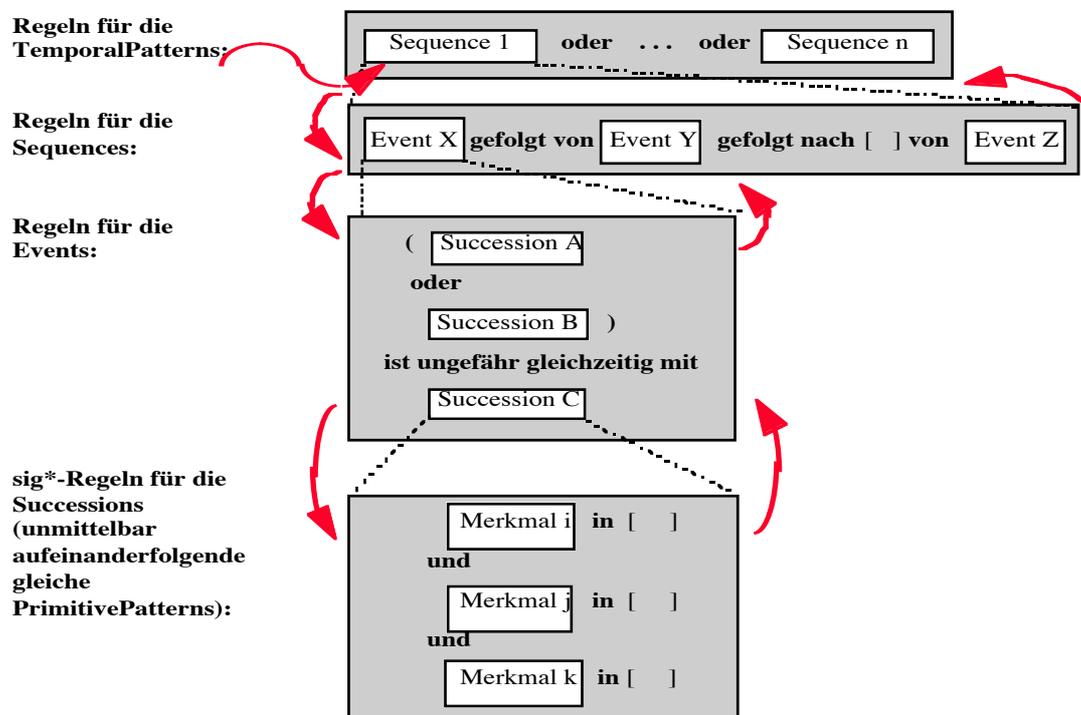


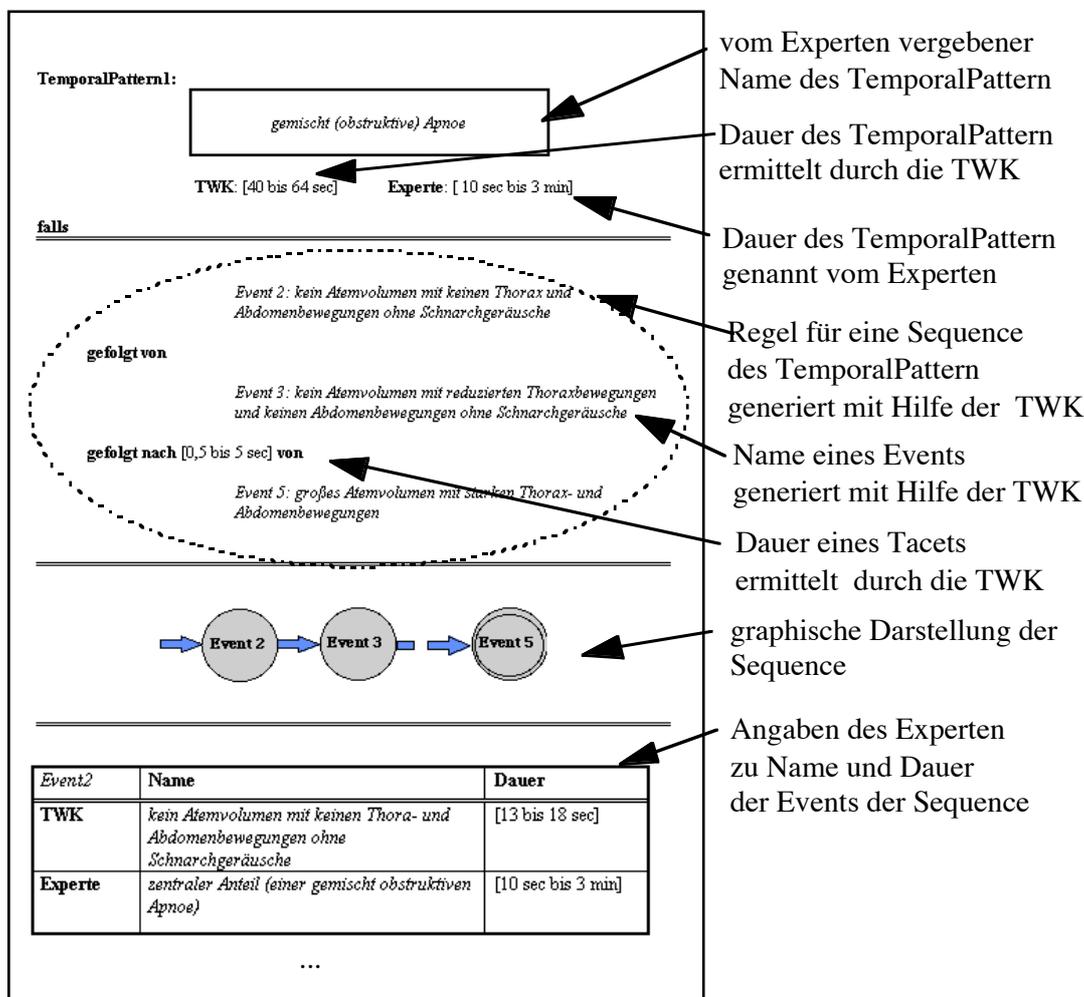
Abb.41: Vorgehensweise bei der Expertenbefragung

Fragen zu Sequences und TemporalPatterns

Anhand einer Graphik mit den Sequences eines TemporalPatterns und den multivariaten Zeitreihen soll zunächst durch einen Experten überprüft werden, ob die Events in den Sequences richtig durch die TWK erkannt worden sind (s. Abb.40). Gleichzeitig wird dem Experten für jede Sequence eines TemporalPatterns eine TG-Regel vorgelegt (s. Abb.42). Der Experte kann nun anhand der Graphiken und der TG-Regeln die zeitliche Abfolge der Events in den Sequences überprüfen. Außerdem existiert für jedes Event ein für die Anwendung ggf. bedeutungsvoller Name. Die Namen der Events werden überprüft, indem die durch den Namen beschriebenen Inhalte mit dem Wissen des Experten verglichen werden. Falls erforderlich, wird die Befragung auf der darunterliegenden Ebene fortgeführt (s. Abb.41).

An dieser Stelle wird auch überprüft, ob die hier durch die TWK vorgeschlagene Zusammenfassung von Sequences zu einem TemporalPattern erlaubt ist. Außerdem erfolgt hier eine Überprüfung der Dauer der Events und des TemporalPatterns. Dem TemporalPattern wird, falls möglich, durch den Experten der

Anwendung ein Name gegeben. Da es sich bei der TWK um eine explorative Methode handelt, wird an dieser Stelle untersucht, ob "neues" Wissen in den Zeitreihen durch die TWK entdeckt worden ist.



vom Experten vergebener Name des TemporalPattern

Dauer des TemporalPattern ermittelt durch die TWK

Dauer des TemporalPattern genannt vom Experten

Regel für eine Sequence des TemporalPattern generiert mit Hilfe der TWK

Name eines Events generiert mit Hilfe der TWK

Dauer eines Tacets ermittelt durch die TWK

graphische Darstellung der Sequence

Angaben des Experten zu Name und Dauer der Events der Sequence

Abb.42: Aufbau eines Fragebogens zur Verifizierung der TG-Regeln der TemporalPatterns

Fragen zu Events

Anhand der TG-Regeln für Events wird überprüft, ob Successions ein Event richtig beschreiben (s. Abb.43). Die Ergebnisse werden dann in eine Tabelle eingetragen, indem angegeben wird, ob zwei Successions ungefähr gleichzeitig auftreten dürfen. Jedem Event wird, falls möglich, ein Name aus der Anwendung gegeben.

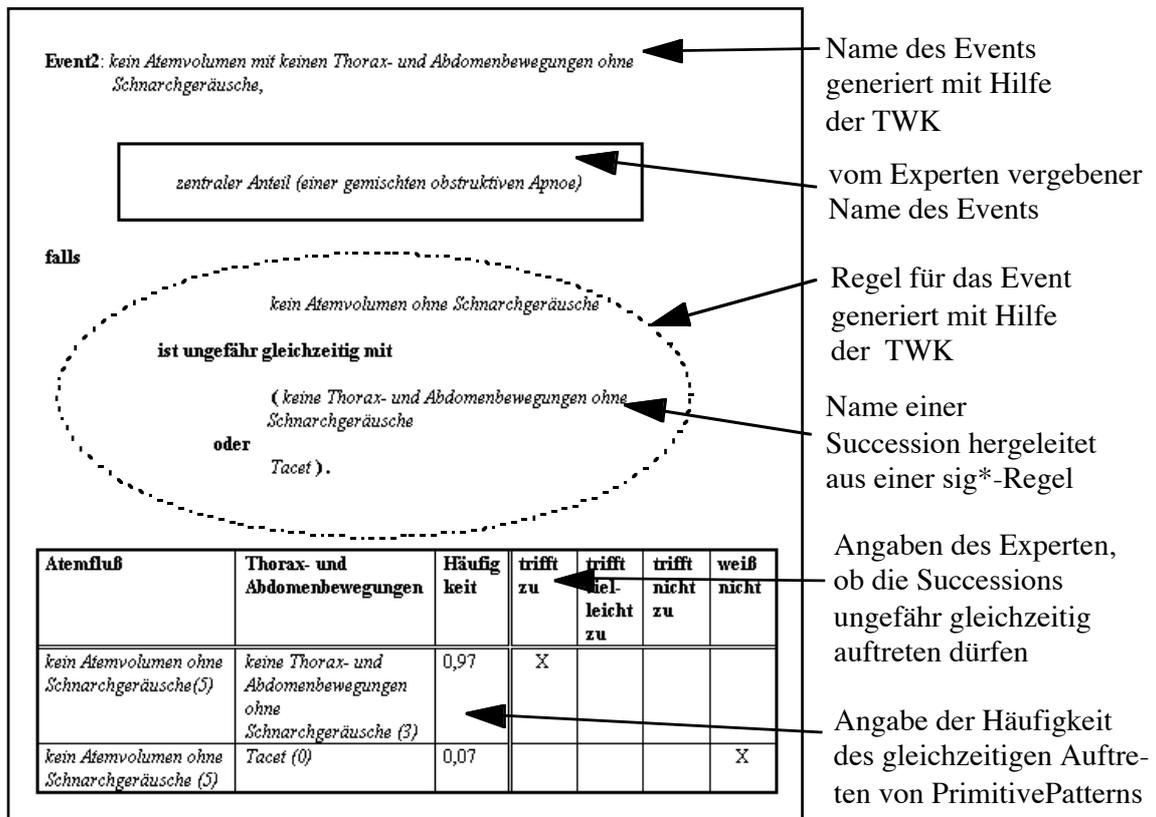


Abb.43: Aufbau eines Fragebogens zur Verifizierung der TG-Regeln der Events

Fragen zu PrimitivePatterns

Die Überprüfung der Namen von Successions bzw. PrimitivePatterns erfolgt anhand der sig*-Regeln. Hierbei können redundante Merkmale möglicherweise unberücksichtigt bleiben. Ein Beispiel für redundante Merkmale ist das Auftreten von *Atemvolumen-groß* = 0.9 und *Atemvolumen-klein* = 0.0 in einer Regel. Für die Namensgebung kann eines der Merkmale unberücksichtigt bleiben. Dies bedeutet nicht, daß eines der Merkmale aus der sig*-Regel entfernt werden kann, da beide Merkmale zur Klassifikation des PrimitivePatterns durch den Regelgenerierungsalgorithmus sig* als signifikant erachtet werden.

5.3.3 Ergebnisse der Expertenbefragung

Durch Befragung des Experten der Anwendung soll die Methode der temporalen Wissenskonversion (TWK) anhand eines real existierenden Anwendungsbeispiels evaluiert werden. Durch die Anwendung der TWK auf schlafbezogene Atmungsstörungen (SBAS) soll gezeigt werden, daß die Entdeckung und Beschreibung von Mustern von SBAS durch die TWK anhand mehrerer Zeitreihen der kardiologische Polysomnographie möglich ist und ggf. "neues" Wissen über die Muster von SBAS durch diese explorative Vorgehensweise entdeckt werden kann. Die entdeckten Muster können anhand der erzeugten TG-Regeln nachvollzogen und überprüft werden. Hierzu wird eine Expertenbefragung durchgeführt, für die ein eigener Fragebogen erstellt worden ist (s. Kapitel 5.3.2). Der zyklische Prozeß einer Expertenbefragung (s. Abb.41) soll hier nicht dargestellt werden. Demgegenüber werden die erzielten Ergebnisse der TWK angewandt aus SBAS für Events und TemporalPatterns in dieser Reihenfolge einzeln vorgestellt. Durch die TWK sind für das Anwendungsbeispiel SBAS vier TemporalPatterns entdeckt worden, die insgesamt durch sechs Events beschrieben werden (s. Kapitel 5.2).

Ergebnisse zu Events

Event 1

Mit Hilfe der TWK ist diesem Event folgender bedeutungsvoller Name gegeben worden:

reduziertes Atemvolumen und reduzierte parallele Thorax- und Abdomenbewegungen mit Schnarchgeräuschen

Der Experte konnte anhand der Zeitreihen dieses Event als "*obstruktives Schnarchen*" identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK.

Der Experte beschrieb *obstruktives Schnarchen* als ein Event, das durch eine regelmäßig auftretende Schnarchintensität und durch parallele Thorax- und Abdomenbewegungen erkannt wird. Die Amplitude der Thorax- und Abdomenbewegungen ist dabei reduziert.

Die erzeugte TG-Regel gibt fast genau die Beschreibung des Experten wieder, da die am häufigsten ungefähr gleichzeitig auftretenden Successions *reduziertes Atemvolumen mit Schnarchgeräuschen* und *reduzierte parallele Thorax- und Abdomenbewegungen mit Schnarchgeräuschen* für das Event zutreffen. Über das un-

gefähr gleichzeitige Auftreten der Successions *Tacet* und *reduzierte parallele Thorax- und Abdomenbewegungen mit Schnarchgeräuschen* konnte keine Aussage gemacht werden (Antwort mit "weiß nicht"), da laut Experte ein *Tacet* keine medizinischen Bedeutung besitzt.

Die Dauer dieses Events wird über die Sauerstoffsättigung bestimmt. Dabei fällt die Sauerstoffsättigung während des obstruktiven Schnarchens langsam ab. Die Sauerstoffsättigung wurde jedoch bei der Erzeugung der Regel nicht berücksichtigt, so daß hier keine Aussage über die Dauer des Events gemacht werden kann.

Event 2

Mit Hilfe der TWK ist diesem Event folgender bedeutungsvoller Name gegeben worden:

kein Atemvolumen mit keinen Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

Der Experte konnte anhand der Zeitreihen dieses Events als "*zentraler Anteil (einer gemischten obstruktiven Apnoe)*" identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK.

Der Experte beschrieb *zentraler Anteil (einer gemischten obstruktiven Apnoe)* als ein Event, bei dem der Atemfluß glatt ist, wobei der Abfall des Signals in Form einer E-Funktion irrelevant ist, und die Thorax- und Abdomenbewegungen flach sind, d.h. keine Atmungsvariationen vorliegen. Der Begriff *zentral* bedeutet, daß die Unterbrechung der Atmung "vom Gehirn aus gesteuert" wird. Die Thorax- und Abdomenbewegungen sind flach, d.h. es liegen keine Atmungsvariationen vor. Dabei ist egal, ob die Intensität der Thoraxbewegungen ansteigend oder abfallend ist. Außerdem ist die Schnarchintensität gering.

Die Erkennung eines *zentralen Anteils (einer gemischten obstruktiven Apnoe)* erfolgt durch folgende Schritte:

1. Es wird überprüft, ob Atemfluß da ist oder nicht. Liegt kein Atemfluß vor, so handelt es sich um eine Apnoe.
2. Für die Atemtätigkeiten wird zwischen *zentral*, *obstruktiv* oder *gemischt* unterschieden. Da in den Thorax- und Abdomenbewegungen keine Atemtätigkeit gefunden wird, handelt es sich um einen *zentralen Anteil*.

Die erzeugte TG-Regel gibt fast genau die Beschreibung des Experten wieder, da die am häufigsten ungefähr gleichzeitig auftretenden Successions *kein Atemvolumen ohne Schnarchgeräusche* und *keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche* für das Event zutreffen. Über das ungefähr gleichzeitige Auftreten der Successions *kein Atemvolumen ohne Schnarchgeräusche* und *Tacet* konnte keine Aussage gemacht werden (Antwort mit “weiß nicht“), da laut Experte ein Tacet keine medizinischen Bedeutung besitzt.

Die durch die TWK bestimmte Dauer von 13 bis 18 sec liegt im gültigen Bereich von 10 sec bis 3 min.

Event 3

Mit Hilfe der TWK ist diesem Event folgender bedeutungsvoller Name gegeben worden:

kein Atemvolumen und reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche

Der Experte konnte anhand der Zeitreihen dieses Event als “*obstruktive Anteil (einer gemischt obstruktiven Apnoe)*“ identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK.

Der Experte beschrieb die Erkennung des *obstruktiven Anteils (einer gemischt obstruktiven Apnoe)* wie folgt:

1. Es wird überprüft, ob Atemfluß da ist oder nicht. Da hier kein Atemfluß vorliegt, ist dies eine Apnoe.
2. Für die Atemtätigkeiten wird zwischen zentral, obstruktiv oder gemischt unterschieden. Da in den Thorax- und Abdomenbewegungen reduzierte Atemtätigkeit gefunden wird, handelt es sich um einen obstruktiven Anteil.

Die erzeugte TG-Regel gibt teilweise die Beschreibung des Experten wieder, da das ungefähr gleichzeitige Auftreten der Successions *kein Atemvolumen ohne Schnarchgeräusche* und *reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche* für das Event nur teilweise zutreffen. Anstatt *keine Abdomenbewegungen* sollten *reduzierte Abdomenbewegungen* auftreten. Dies wird wie folgt erklärt:

1. *Kein Atemvolumen* läßt auf eine Apnoe schließen.

2. *Reduzierte Thoraxbewegungen* bedeuten, daß eine Atemtätigkeit vorhanden ist und daß sie auf eine Obstruktion schließen lassen.
3. Dem stehen gegenüber *keine Abdomenbewegungen ohne Schnarchgeräusche*, die nicht auf eine Obstruktion schließen lassen.

Die durch die TWK bestimmte Dauer von 20 bis 39 sec liegt im gültigen Bereich von 10 sec bis 3 min.

Event 4

Mit Hilfe der TWK ist diesem Event folgender bedeutungsvoller Name gegeben worden:

kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

Der Experte konnte anhand der Zeitreihen dieses Event als “*obstruktive Apnoe*“ identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK.

Der Experte beschrieb *obstruktive Apnoe* als ein Auftreten von sowie parallel als auch gegenläufig verlaufenden Thorax- und Abdomenbewegungen. Parallele Atmungsbewegungen bedeuten, daß ein effektiver Atemfluß stattfindet. Gegenläufige Atmungsbewegungen bedeuten, daß kein oder ein stark verminderter Atemfluß vorhanden ist.

Die erzeugte Regel gibt im wesentlichen die Beschreibung des Experten wieder, insbesondere daß die Thorax- und Abdomenbewegungen parallel und gegenläufig verlaufen. *Reduzierte parallele und phasenverschobene Thorax- und Abdomenbewegungen* in der TG-Regel lassen auf eine Obstruktion schließen und dürfen mit den Successions *geringes Atemvolumen ohne Schnarchgeräusche* und *kein Atemvolumen ohne Schnarchgeräusche* ungefähr gleichzeitig auftreten. Über das ungefähr gleichzeitige Auftreten von *Tacet* und *reduzierte parallele und phasenverschobene Thorax- und Abdomenbewegungen* konnte keine Aussage gemacht werden (Antwort mit “weiß nicht“), da laut Experte ein *Tacet* keine medizinischen Bedeutung besitzt.

Die durch die TWK bestimmte Dauer von 10 bis 30 sec liegt im gültigen Bereich von 10 sec bis 3 min.

Event 5

Mit Hilfe der TWK ist diesem Event folgender bedeutungsvoller Name gegeben worden:

großes Atemvolumen und starke Thorax- und Abdomenbewegungen mit Schnarchgeräuschen

Der Experte konnte anhand der Zeitreihen dieses Event als “*Hyperpnoe (Hyperventilation)*“ identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK.

Der Experte beschrieb *Hyperpnoe* als eine Ereignis, daß immer eine Apnoe oder Hypopnoe beendet. Dabei treten verstärkte Atemtätigkeiten ein. Eine *Hyperpnoe* dauert einen oder wenige Atemzüge an, während eine Hyperventilation einen längeren Zeitraum andauert, z.B. vor dem Tauchen. Eine Hypopnoe kann anders aussehen, falls sich der Patient auf die Seite legt oder aufwacht.

Die erzeugte Regel gibt fast genau die Beschreibung des Experten wieder, wobei hauptsächlich die Successions *großes Atemvolumen mit Schnarchgeräuschen* und *starke Thorax- und Abdomenbewegungen* ungefähr gleichzeitig aufgetreten sind. Es konnten vom Experten keine Aussagen über das ungefähr gleichzeitige Auftreten von *Tacet* oder *reduziertes Atemvolumen mit Schnarchgeräuschen* mit *starke Thorax- und Abdomenbewegungen* gemacht werden (Antwort mit “weiß nicht“).

Die durch die TWK bestimmte Dauer liegt im Intervall von 3 sec bis 16 sec. Nach Meinung des Experten sind 3 sec zu wenig, ca. 10 sec sind eher passend.

Event 6

Mit Hilfe der TWK ist diesem Event folgender bedeutungsvoller Name gegeben worden:

kein bis reduziertes Atemvolumen und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

Der Experte konnte anhand der Zeitreihen dieses Event als “*Hypopnoe*“ identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK.

Der Experte beschrieb die *Hypopnoe* als ein Event, das folgendermaßen erkannt werden kann.

1. Die Amplitude des Atemflusses wird mit der Amplitude der Normalatmung verglichen. Falls diese um $<50\%$ reduziert ist, dann handelt es sich um eine Hypopnoe. Falls diese um 10 - 20 % reduziert ist, dann handelt es sich um eine Apnoe. Hier liegt noch Atemfluß vor, daher handelt es sich um eine Hypopnoe.
2. Durch Betrachtung der Atmungsbewegungen wird untersucht, ob Obstruktion in Form eines Trapezes ansteigt. Die korrekte Erfassung der Dauer der Hypopnoe ist dabei ein wichtiges Kriterium bei der Erkennung einer Hypopnoe.
3. Es wird die Phase zwischen Thorax- und Abdomenbewegungen betrachtet. Da eine gegenläufige Tätigkeit der Atmungsbewegungen vorliegt, handelt es sich um eine Hypopnoe.

Die erzeugte Regel gibt fast genau die Beschreibung des Experten wieder, wobei hauptsächlich die Successions *geringes Atemvolumen ohne Schnarchgeräusche* oder *reduziertes Atemvolumen ohne Schnarchgeräusche* und die Succession *phasenverschobene Thorax- und Abdomenbewegungen* ungefähr gleichzeitig auftreten. Das bedeutet, daß eine gegenläufige Tätigkeit der Atmungsbewegungen vorliegt, die die TWK richtig erkannt hat. Es konnte keine Aussage vom Experten über das ungefähr gleichzeitige Auftreten von *reduziertes Atemvolumen ohne Schnarchgeräusche* und *Tacet* gemacht werden (Antwort mit "weiß nicht"), da laut Experte ein *Tacet* keine medizinischen Bedeutung besitzt.

Bei einer Hypopnoe kann ein *reduziertes Atemvolumen* "mit" *Schnarchgeräuschen* oder "ohne" *Schnarchgeräusche* auftreten. Durch die Regel wurde nur ein *reduziertes Atemvolumen ohne Schnarchgeräusche* festgestellt. Dies ist darauf zurückzuführen, daß ein *reduziertes Atemvolumen mit Schnarchgeräuschen* für diese Event in den Daten nicht vorgekommen ist.

Die durch die TWK bestimmte Dauer von 13 sec bis 18 sec liegt im gültigen Bereich von 10 sec bis 3 min.

Ergebnisse zu TemporalPatterns und Sequences

Die Ergebnisse für TemporalPatterns und Sequences werden zusammen betrachtet, da es sich bei den TemporalPattern lediglich um Alternativen von Sequences handelt. Das bedeutet, daß im folgenden für jedes TemporalPattern die Ergebnisse der Expertenbefragung für die Sequences dieses TemporalPattern vorgestellt werden.

TemporalPattern 1

Der Experte konnte anhand der Zeitreihen dieses TemporalPattern als “*gemischte (obstruktive) Apnoe*“ identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK.

Der Experte beschrieb das TemporalPattern als *gemischte (obstruktive) Apnoe*, da überprüft wird, ob es einen zentralen und einen obstruktiven Anteil gibt, die zeitlich gemischt sind.

Die erzeugte TG-Regel gibt genau die Beschreibung des Experten wieder, da ein *zentraler Anteil*, durch die TWK bezeichnet als *kein Atemvolumen mit keinen Thorax- und Abdomenbewegungen ohne Schnarchgeräusche*, von einem *obstruktiven Anteil einer gemischt obstruktiven Apnoe*, durch die TWK bezeichnet als *kein Atemvolumen und reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche*, gefolgt wird. Eine *gemischt (obstruktive) Apnoe* wird durch eine *Hyperpnoe* beendet, die durch die TWK als *großes Atemvolumen und starke Thorax- und Abdomenbewegungen mit Schnarchgeräuschen* bezeichnet wird.

Die durch die TWK bestimmte Dauer von 40 bis 64 sec liegt im gültigen Bereich von 10 sec bis 3 min. Die Dauer der *gemischt (obstruktiven) Apnoe*, zusammengesetzt aus einem zentralen und einem obstruktiven Anteil, muß länger als 10 sec sein.

TemporalPattern2

Der Experte konnte anhand der Zeitreihen dieses TemporalPattern als “*obstruktive Hypopnoe*“ identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK.

Der Experte beschrieb die *obstruktive Hypopnoe* als ein TemporalPattern, das folgendermaßen erkannt werden kann (s. a. *Event 6*).

1. Die Amplitude des Atemflusses wird mit der Amplitude der Normalatmung verglichen. Falls diese um <50% reduziert ist, handelt es sich um eine Hypopnoe. Falls diese um 10 - 20 % reduziert ist, handelt es sich um eine Apnoe. Hier liegt noch Atemfluß vor, daher handelt es sich um eine Hypopnoe.
2. Durch Betrachtung der Atmungsbewegungen wird untersucht, ob Obstruktion in Form eines Trapezes ansteigt. Die korrekte Erfassung der

Dauer der Hypopnoe ist dabei ein wichtiges Kriterium bei der Erkennung einer Hypopnoe.

3. Es wird die Phase zwischen Thorax- und Abdomenbewegungen betrachtet. Da eine gegenläufige Tätigkeit der Atmungsbewegungen vorliegt, handelt es sich um eine Hypopnoe.
4. Eine obstruktive Hypopnoe wird stets durch eine Hyperpnoe beendet.

Die erzeugte Regel gibt genau die Beschreibung des Experten wieder, wobei das TemporalPattern aus den beiden Sequences *Sequence2* und *Sequence3* zusammengesetzt ist (s. Kapitel 5.2.5). *Sequence 2* besteht aus einer *Hypopnoe*, durch die TWK bezeichnet als *kein bis reduziertes Atemvolumen und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche*, beendet durch eine *Hyperpnoe*, die durch die TWK als *großes Atemvolumen und starke Thorax- und Abdomenbewegungen mit Schnarchgeräuschen* bezeichnet wird. In *Sequence 3* tritt zeitlich vor der *Hypopnoe* eine *obstruktive Apnoe*, durch die TWK bezeichnet als *kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche*. Diesem Event wird vom Experten keine Bedeutung beigemessen. Möglicherweise handelt es sich um einen ausgelassenen Atemzug. Dieses Ereignis wäre näher zu untersuchen, falls es häufiger auftreten würde.

Die durch die TWK bestimmte Dauer von 18 bis 35 sec liegt im gültigen Bereich von 10 sec bis 3 min.

TemporalPattern3

Der Experte konnte anhand der Zeitreihen dieses TemporalPattern als “*gemischte obstruktive Apnoe*“ identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK. Nach Aussagen des Experten existiert bisher für dieses Muster von SBAS noch keine Definition in der Medizin.

Der Experte beschrieb das TemporalPattern als eine von der Atemtätigkeit her *gemischte Apnoe*, da ein zentraler Atemstillstand vorliegt. Es liegt auch eine Obstruktion vor, da vor Ende der Apnoe Schnarchgeräusche auftreten und kleine Atembewegungen wieder im Luftfluß auftreten. Die Obstruktion der oberen Atemwege ist nicht komplett, und der Patient bekommt schon vor Ende der Apnoe wieder Luft. Bisher existiert für dieses Muster noch keine Definition in der Medizin. TemporalPattern3 wird in 2 Typen unterschieden:

1. *Gemischte obstruktive Apnoe* mit Unterbrechung und mit Schnarchgeräuschen, wobei ein zentraler und ein obstruktiver Anteil vorliegt.
2. *Gemischte obstruktive Apnoe* ohne Unterbrechung und ohne Schnarchgeräusche, wobei eine obstruktive Apnoe vorliegt.

Die erzeugte Regel gibt genau die Beschreibung des Experten wieder, wobei das TemporalPattern aus den beiden Sequences *Sequence4* und *Sequence5* zusammengesetzt ist (s. Kapitel 5.2.5). *Sequence4* besteht aus einer *obstruktiven Apnoe*, durch die TWK bezeichnet als *kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche* und *Sequence5* besteht aus zwei aufeinanderfolgenden *obstruktiven Apnoen*, die durch ein *EventTacet* unterbrochen werden. Daß bei *Sequence5* zum Ende hin eine Hypoventilation eintritt, wurde hier nicht erkannt. Dieses Ereignis wird durch den Atemfluß und mitunter auch durch die Schnarchgeräusche erkannt. Beide Sequences werden durch eine *Hyperpnoe* beendet, die durch die TWK als *großes Atemvolumen und starke Thorax- und Abdomenbewegungen mit Schnarchgeräuschen* bezeichnet wird.

Die durch die TWK bestimmte Dauer von 18 bis 30 sec liegt im gültigen Bereich von 10 sec bis 3 min.

TemporalPattern 4

Der Experte konnte anhand der Zeitreihen dieses TemporalPattern als “*obstruktives Schnarchen*“ identifizieren und bestätigte eine richtige Erkennung des Events durch die TWK.

Der Experte beschrieb *obstruktives Schnarchen* als ein TemporalPattern, das durch eine regelmäßig auftretende Schnarchintensität und durch parallele Thorax- und Abdomenbewegungen erkannt wird. Die Amplitude der Thorax- und Abdomenbewegungen ist dabei reduziert (s. a. *Event 1*).

Die erzeugte Regel gibt fast genau die Beschreibung des Experten wieder, da das TemporalPattern durchweg durch das Event *reduzierte Atmung* (Atemfluß und Atmungsbewegungen) *mit Schnarchgeräuschen* beschrieben wird.

Die Dauer des TemporalPatterns konnte hier nicht festgestellt werden, da einerseits ein zu kleines Zeitfenster verwendet wurde, und andererseits die Sauerstoffsättigung zur Erkennung von Mustern in SBAS nicht verwendet wurde.

Im folgenden werden die Ergebnisse der TWK angewandt auf SBAS zusammengefaßt dargestellt. Dabei werden folgende Fragestellung beantwortet:

1. Werden TemporalPatterns, Sequences und Events durch die TWK richtig erkannt?
2. Liegt die durch die TWK bestimmte Dauer von TemporalPatterns, Sequences und Events in einem gültigen Wertebereich?
3. Liefern die TG-Regeln für TemporalPatterns, Sequences und Events eine adäquate und für die Anwendung sinnvolle Beschreibung?
4. Konnten TemporalPatterns und Events durch einen Experten anwendungsbezogene Namen gegeben werden?
5. Ist durch die TWK in den Zeitreihen "neues" Wissen entdeckt worden?

Wie bereits in Kapitel 5.3.1 dargestellt, werden einem Experten der Anwendung Graphiken mit den entdeckten TemporalPatterns und Events zusammen mit den Zeitreihen vorgelegt (s. Abb.40). Hierdurch kann eine visuelle Überprüfung von TemporalPatterns und Events durch einen Experten der Anwendung stattfinden. Dabei ist festgestellt worden, daß durch die TWK alle TemporalPatterns und Events richtig entdeckt bzw. erkannt worden sind. Insbesondere ist *Event 5: Hyperpnoe* richtig durch die TWK als End-Event identifiziert worden, da Apnoen oder Hypopnoen stets mit einer Hyperpnoe enden.

Für die Identifikation von TemporalPatterns und Events ist die Dauer der durch die TWK bestimmten TemporalPatterns und Events relevant, da die Dauer in den Bedingungen der TG-Regeln überprüft wird. Daher wird im Rahmen einer Expertenbefragung geprüft, ob die Dauer von TemporalPatterns und Events in einem gültigen Wertebereich liegt. Bei der Expertenbefragung ist festgestellt worden, daß die Dauer fast aller Events und sogar aller TemporalPatterns in einem für die Anwendung gültigen Wertebereich liegt. Lediglich bei *Event5: Hyperpnoe* sind einige wenige Fälle aufgetreten, bei denen die Dauer des Events von ca. 3 sec nach Meinung des Experten zu kurz ist.

Durch die TWK werden nicht nur komplexe Muster in multivariaten Zeitreihen entdeckt, sondern sie werden außerdem durch TG-Regeln in eine sprachliche, für Menschen verständliche Form überführt. Im Rahmen der Expertenbefragung ist daher zu untersuchen, ob das durch die TWK gewonnene Wissen über die komplexen Muster mit dem Wissen eines Experten übereinstimmt, d.h. die Beschreibungen von TemporalPatterns und Events durch TG-Regeln das Wissen des Experten widerspiegeln. Da Sequences in den TemporalPatterns aus Folgen von

Events bestehen, ist zunächst zu überprüfen, ob Events einen Sinn für die Anwendung haben. Hierzu werden folgende Eigenschaften der ungefähr gleichzeitigen Successions in den Events geprüft:

1. Die Successions dürfen in dem Event zusammen auftreten (Antwort: "trifft zu").
2. Die Successions dürfen in dem Event vielleicht zusammen auftreten (Antwort: "trifft vielleicht zu").
3. Vom Experten kann keine Aussage über das Auftreten der Successions in dem Event gemacht werden (Antwort: "weiß nicht").
4. Die Successions dürfen in dem Event nicht zusammen auftreten (Antwort: "trifft nicht zu").

Bei Befragung des Experten stellte sich heraus, daß die Beschreibungen durch TG-Regeln für die Events zum größten Teil mit dem Wissen des Experten übereinstimmen (s. Abb.44).

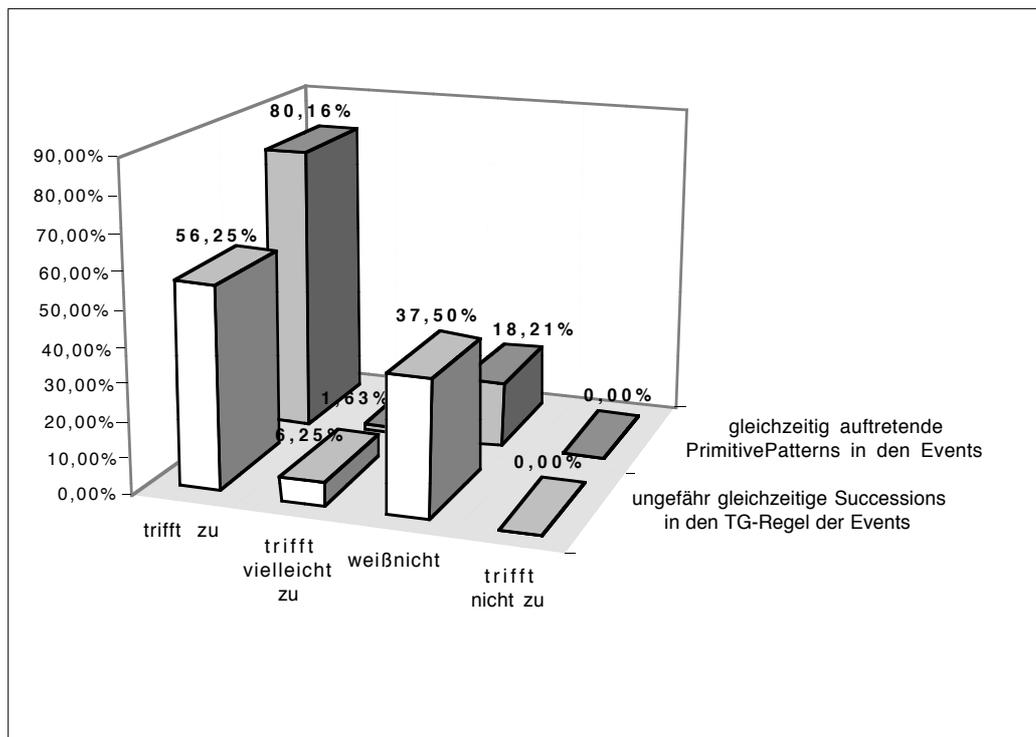


Abb.44: Ergebnisse der Expertenbefragung für alle Events

Insgesamt sind 56,25% der ungefähr gleichzeitig auftretenden Successions den Events richtig zugeordnet worden (Antwort: "trifft zu"). Die Bedeutung dieser Prozentzahl wird außerdem verstärkt, wenn berücksichtigt wird, daß dies für 80,16% der Fälle insgesamt gilt. Für 37,5% der ungefähr gleichzeitig auftretenden Successions konnte vom Experten keine Aussage gemacht werden (Antwort: "weiß nicht"). Hierbei handelte es sich hauptsächlich um Successions, die mit Tacets ungefähr gleichzeitig aufgetreten sind (s. Anhang A.7). Tacets kann nach Meinung des Experten keine medizinische Bedeutung beigemessen werden. Die Bedeutung dieser relativ hohen Prozentzahl verringert sich, wenn gleichzeitig berücksichtigt wird, daß dies nur für insgesamt 18,21% der Fälle gilt. Auffallend ist, daß keine unzutreffenden ungefähr gleichzeitigen Successions in den Events aufgetreten sind (Antwort: "trifft nicht zu"). In Abb.45 werden die Ergebnisse für die Events nochmals für jedes einzelne Event getrennt betrachtet. Dabei wird z.B. die Bezeichnung Event 3.1 folgendermaßen interpretiert: es handelt sich hier um die ersten ungefähr gleichzeitig auftretenden Successions in *Event 3*.

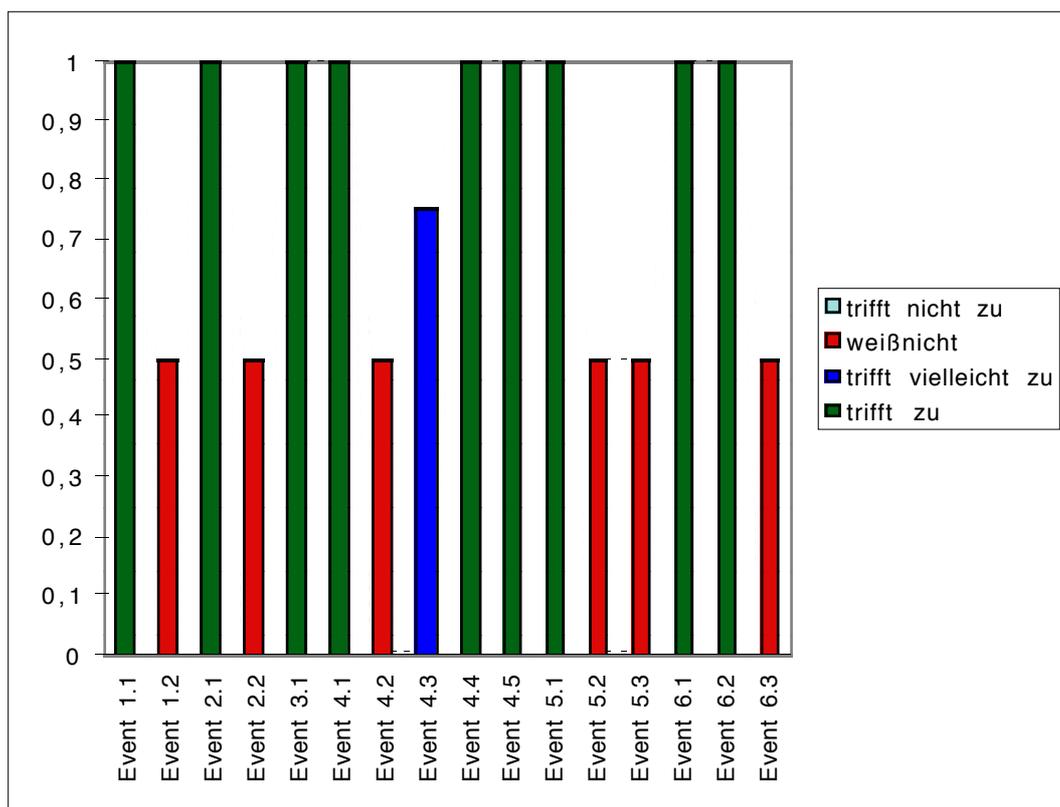


Abb.45: Ergebnisse der Expertenbefragung für die ungefähr gleichzeitig auftretenden Successions in den TG-Regeln der Events

Da durch eine TG eine für Menschen verständliche Beschreibung von komplexen Mustern in einer sprachlichen Form generiert werden soll, werden die TG-Regeln vom Experten bezüglich ihrer Verständlichkeit und Interpretierbarkeit eingeschätzt. Dies bezieht sich insbesondere auf die Verständlichkeit der Sprachkonstrukte, die in den TG-Regeln verwendet werden. Die Sprachkonstrukte **‘gefolgt von’**, **‘gefolgt nach [Dauer] von’** und **‘oder’** eignen sich nach Aussagen des Experten zur Beschreibung von zeitlichen Phänomenen. Für das Sprachkonstrukt **‘ist ungefähr gleichzeitig mit’** ist denkbar, daß diese Formulierung eher ungeeignet ist, da kleine Abweichungen vom gleichzeitigen Auftreten für die Anwendung irrelevant sind. Hier stellt sich die Frage, ob auf eine mathematisch präzisere Beschreibung durch das Sprachkonstrukt **‘ungefähr gleichzeitig’** verzichtet werden kann und anstatt dessen eher das Sprachkonstrukt **‘gleichzeitig’** verwendet werden sollte.

Bei der Expertenbefragung sollen den TemporalPatterns und Events, falls möglich, Namen aus der Anwendung gegeben werden. Die durch die TWK erzeugten bedeutungsvollen Namen für die Events sollten hier zunächst überprüft werden. Durch den Experten der Anwendung konnte jedem TemporalPattern und jedem Event ein Name aus der Medizin zugeordnet werden (s. a. Anhang A.7):

- *TemporalPattern 1: gemischte (obstruktive) Apnoe*
- *TemporalPattern 2: obstruktive Hypopnoe*
- *TemporalPattern 3: gemischte obstruktive Apnoe*
- *TemporalPattern 4: obstruktives Schnarchen*
- *Event 1: obstruktives Schnarchen*
- *Event 2: zentraler Anteil (einer gemischten obstruktiven Apnoe)*
- *Event 3: obstruktiver Anteil (einer gemischten obstruktiven Apnoe)*
- *Event 4: obstruktive Apnoe*
- *Event 5: Hyperpnoe*
- *Event 6: Hypopnoe*

Ziel einer explorativen Methode, wie es die TWK ist, ist nicht nur die Erkennung von bereits bekanntem Wissen. Ein besonderes Interesse gilt auch der Entdeckung von "neuem" Wissen. Einen Hinweis für ggf. "neu" entdecktes Wissen liefert *TemporalPattern3: gemischte obstruktive Apnoe*. Bisher existiert für dieses Muster noch keine exakte Definition in der Medizin. Dieses TemporalPattern wird in zwei Typen unterschieden, die auch richtig durch die TWK in den Zeitreihen erkannt worden sind:

1. *gemischte obstruktive Apnoe* mit Unterbrechung und mit Schnarchgeräuschen, wobei ein zentraler und ein obstruktiver Anteil vorliegt und
2. *gemischte obstruktive Apnoe* ohne Unterbrechung und ohne Schnarchgeräusche, die zum Ende hin zu einer Hypoventilation wird.

Zusammenfassend gilt, daß alle Events und TemporalPatterns durch die TWK richtig erkannt worden sind, und sogar zum größten Teil durch die TG-Regeln korrekt wiedergegeben worden sind, so daß eine inhaltliche Überprüfung der TG-Regeln durch einen Experten der Anwendung erfolgen konnte. Insbesondere ist *Event 5: Hyperpnoe* richtig als Endevent identifiziert worden. Außerdem konnte jedem Event und TemporalPattern ein Name aus der Anwendung durch den Experten gegeben werden. Letztendlich ist ein Hinweis auf "neues" Wissen in *TemporalPattern3: gemischte obstruktive Apnoe* gefunden worden.

Kapitel 6

Diskussion

In diesem Kapitel wird die Methode zur temporalen Wissenskonversion (TWK) mit anderen Ansätzen verglichen.

In Kapitel 6.1 wird der Einsatz von selbstorganisierenden Merkmalskarten (SOM) zur Verarbeitung von Zeit diskutiert. Dabei wird unser Ansatz zur Visualisierung von zeitlichen Verläufen durch Wege auf U-Matrizen für hierarchische selbstorganisierende Merkmalskarten (SOM) im Zusammenhang mit existierenden Ansätzen zur Verarbeitung von Zeit mit SOM erörtert.

Ein Ziel dieser Arbeit ist es gewesen, eine geeignete Wissensrepräsentation zur Beschreibung von komplexen Mustern in multivariaten Zeitreihen zu finden. Daher wird in Kapitel 6.2 zunächst unser Ansatz mit anderen Ansätzen aus der Künstlichen Intelligenz (KI) zur Repräsentation von Zeit verglichen. Wenn auch infolge der Problemstellung Analogien zur syntaktischen Mustererkennung existieren, so sollen hier Unterschiede zu den anderen Ansätzen verdeutlicht werden.

In Kapitel 6.3 wird die TWK in die verschiedenen Typen von Hybriden Systemen eingeordnet. Der hier vorgeschlagene Ansatz zur Entdeckung und Generierung von temporalem Wissen durch einen Übergang zwischen verschiedenen Wissensrepräsentationsformen ist eine neuartige Methode, wie sie in dieser Art und Weise bisher für multivariate Zeitreihen noch nicht existiert.

6.1 Selbstorganisierende Merkmalskarten (SOM) zur Verarbeitung von Zeit

Es existieren prinzipiell zwei Möglichkeiten für die Darstellung von Zeit mit Selbstorganisierenden Merkmalskarten (SOM). Einerseits existieren Ansätze, bei denen zeitliche Verläufe durch Wege auf SOM graphisch dargestellt werden [Kohonen 88, Mujunen et al. 93, Behme et al. 93, Tuya et al. 93, Kita/Nishihawa 93, Harris 93, Kaski/Joutsienimi 93, Joutsienimi et al. 95, Principe/Wang 95, Lin et al. 97]. Hier wird keine Veränderung des ursprünglichen Kohonen-Algorithmus vorgenommen, sondern Zeit wird direkt auf einer SOM bzw. auf einer aus den angelernten Netzstrukturen erzeugten graphischen Darstellung von SOM wie z.B. den U-Matrizen visualisiert. Andererseits existieren Ansätze, bei denen Zeit erst durch eine Veränderung des Kohonen-Algorithmus bzw. der Netztopologie verarbeitet werden kann [Tavan et al. 90, Kohonen 91, Ritter et al. 89, Ritter et al. 92, Walter/Schulten 93, Heikkonen et al. 93, Kemke/Wichert 93, So/Chan 94, Hung/Lin 94, Weierich/ Rosenberg 94, Jiang et al. 94, Principe/Wang 95, Ultsch et al. 96, Röske 97, Koh et al. 95, Andrade et al. 97]. Es handelt sich hierbei um Verfahren, bei denen der Kohonen-Algorithmus zu einem überwachten Lernverfahren modifiziert wird, sowie um rekurrente und hierarchische SOM.

Bei den meisten Ansätzen zur Visualisierung von zeitlichen Verläufen auf SOM werden Wege direkt auf einer SOM ohne eine zusätzliche Visualisierung der angelernten Netzstrukturen betrachtet. Zunächst wurde dieser Ansatz in der Sprachverarbeitung [Kohonen 88, Kohonen 89, Leinonen et al. 92, Utela et al. 92, Leinonen et al. 93, Mujunen et al. 93, Behme et al. 93, Tuya et al. 93, Kita/Nishihawa 93] und zum Monitoring und zur Steuerung von Prozessen [Harris 93] eingesetzt. In den letzten Jahren wurde dieser Ansatz immer häufiger zur Analyse und Klassifikation von Zeitreihen verwendet [Kaski/Joutsienimi 93, Joutsienimi et al. 95, Principe/Wang 95, Lin et al. 97].

Die Visualisierung von Wegen direkt auf einer SOM wurde zuerst in der Spracherkennung eingesetzt [Kohonen 88, Kohonen 89]. Bei diesen Ansätzen wird das Sprachsignal segmentiert, um daraufhin eine Spektralanalyse durchführen zu können. Jeder Eingabevektor entspricht einem Phonem, so daß ähnliche Phoneme bzgl. ihres Frequenzspektrums in einer Nachbarschaft auf einer ausgelernten Merkmalskarte liegen (s. Abb.46). Eine Zuordnung der verschiedenen Typen von Phonemen zu den Bestmatches auf einer Merkmalskarte ist möglich, da eine Klassifikation der verschiedenen Typen bereits a priori existiert. Ein Wort wie z.B. das Wort "humppila" wird als Weg auf einer Merkmalskarte dargestellt (s. Abb.47).

Um ein Wort in größere Segmente wie z.B. Silben zerlegen zu können, werden Abstände zwischen zwei zeitlich aufeinanderfolgende Bestmatches auf einer Merkmalskarte betrachtet [Behme et al. 93]. Ein Übergang zu einer neuen Silbe wird dadurch erkannt, daß ein größerer Abstand zwischen zwei zeitlich aufeinanderfolgenden Bestmatches auf einer Merkmalskarte auftritt.

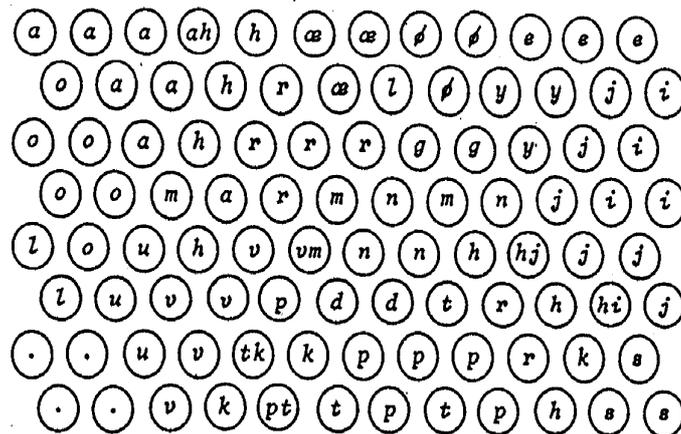


Abb.46: Merkmalskarte mit 21 finnischen Phonemen (in [Kohonen 88]).

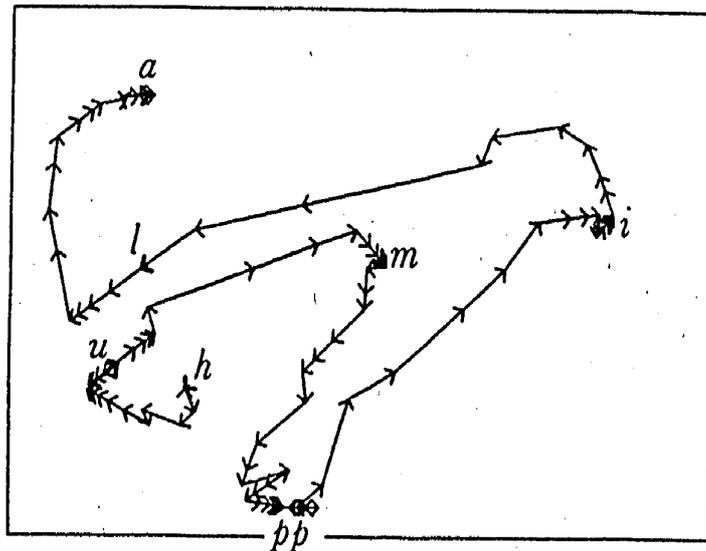


Abb.47: Weg auf einer SOM für das finnische Wort "humppila" (in [Kohonen 88]).

In der Spracherkennung sind Wege direkt auf SOM außerdem zur Identifikation von falsch ausgesprochenen "s"-Lauten von 11 Frauen im Alter von 16-18 Jahren eingesetzt worden, die auditiv als normal, akzeptabel und unakzeptabel beurteilt worden sind [Leinonen et al. 92, Mujunen et al. 93, Leinonen et al. 93]. Zur Unterscheidung zwischen den drei Kategorien werden Wege betrachtet. Normal ausgesprochene "s"-Laute sollten dabei innerhalb eines bestimmten Bereiches (schraffierter Bereich) auf einer Merkmalskarte liegen. Es konnten deutlich unterschiedliche Verläufe auf einer Merkmalskarte bei Frauen mit normaler und unakzeptabler Aussprache von "s"-Lauten erkannt werden (s. Abb.48). Eine zusätzliche Bewertung von Wegen erfolgte durch die Ermittlung des Durchschnitts von Positionen der Bestmatches eines Weges auf einer Merkmalskarte. Ziel war es, Frauen mit einer falschen Aussprache von "s"-Lauten zu erkennen und einer Sprachtherapie zu unterziehen.

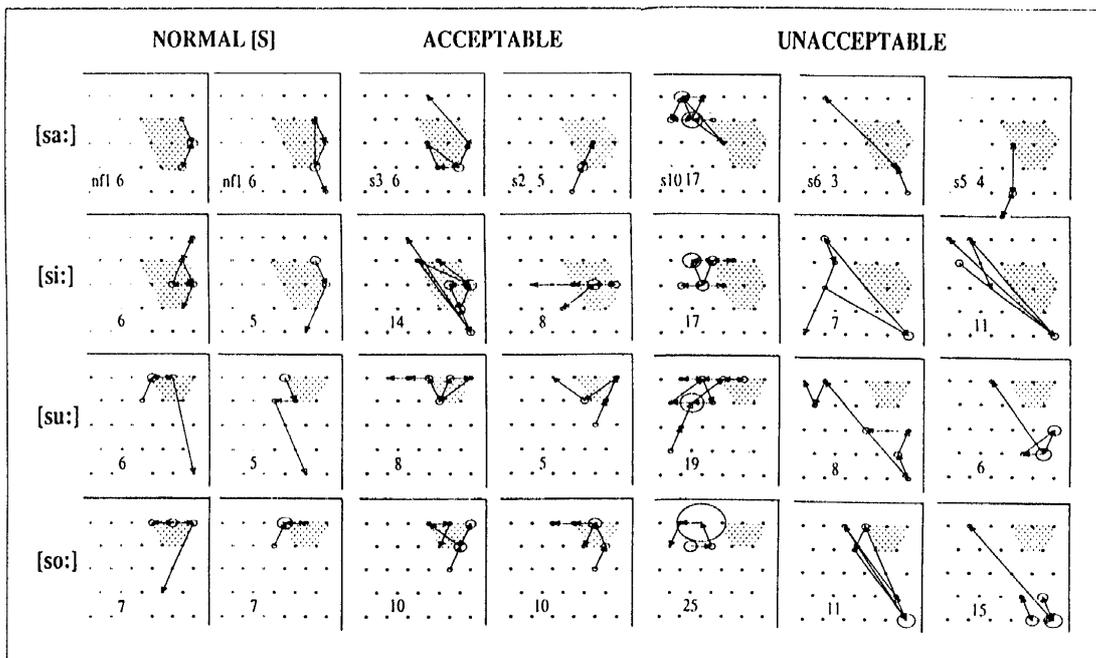


Abb.48: Wege auf SOM zur Identifikation von normaler, akzeptabler und unakzeptabler Aussprache von "s"-Lauten von 11 Frauen im Alter von 16-18 Jahren (in [Mujunen et al. 93])

Ein weiteres Anwendungsbeispiel zur Darstellung von Wegen direkt auf SOM ist das Monitoring von medizinischen Geräten [Harris 93]. Bei diesem Ansatz werden verschiedene Frequenzbänder von Maschinengeräuschen aufgenommen und

zum Anlernen einer SOM verwendet. Da der Lerndatensatz sowohl Maschinengeräusche im normalen Zustand wie auch in fehlerhaften Zuständen enthält, bilden sich Bereiche auf der Merkmalskarte aus, die sowohl normalen als auch fehlerhaften Zuständen einer Maschine entsprechen. Abweichungen eines Weges von dem als normal klassifizierten Bereich werden dann als Fehlzustände interpretiert.

Im Bereich der Zeitreihenanalyse sind Wege direkt auf SOM beispielsweise zum Monitoring von EEG Signalen eingesetzt worden [Kaski/Joutsienimi 93, Joutsienimi et al. 95]. Es werden 22 Signale aufgenommen und die abgetasteten Signale aus mehreren Zeitfenstern in den Frequenzbereich überführt. Außerdem wird eine Klassifikation der Zeitfenster in sechs bekannte EEG Phänomene wie z.B. Alpha-Wellen oder Muskelbewegungen durchgeführt. Zeitliche Strukturen in den 22 Zeitreihen werden dadurch erkannt, daß unterschiedliche Wege andere Klassen auf einer Merkmalskarte durchlaufen (s. Abb.49).

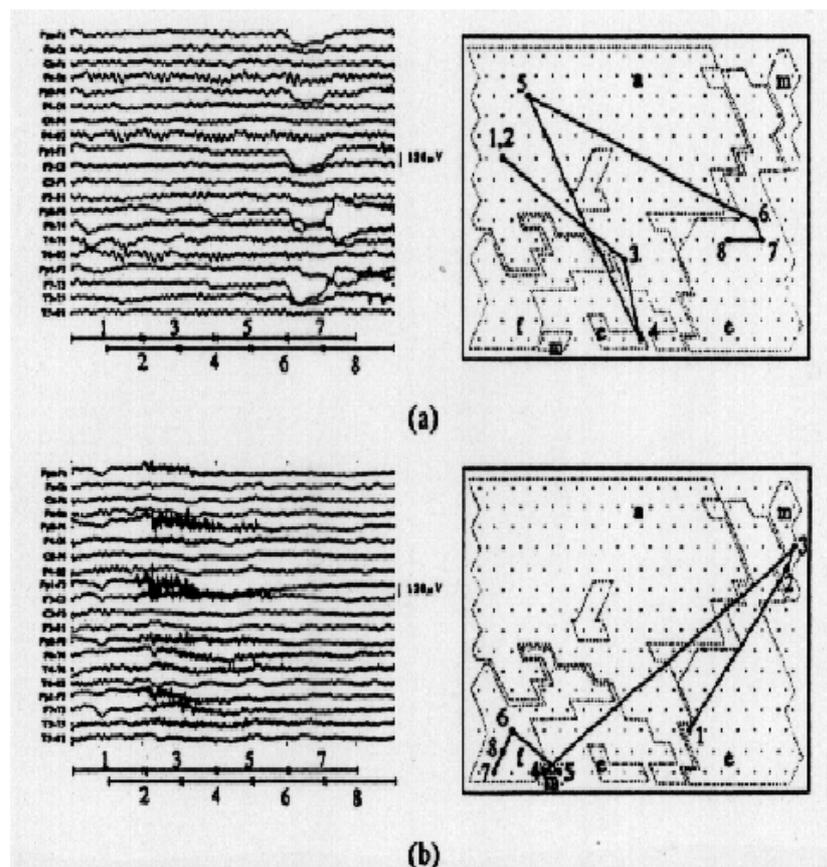


Abb.49: Wege von zwei verschiedenen Ausschnitten eines EEG's (in [Joutsienimi et al. 95]).

In Principe/Wang (1995) werden die Vorteile von SOM zur lokalen Approximation von nichtlinearen Zeitreihen aufgezeigt. Bei diesem Ansatz besteht ein Eingabevektor aus einem $n+1$ dimensionalen Zustandsraumvektor $[\hat{x}(n), x(n + \tau)]^T$, wobei $\hat{x}(n) = [x(n - (N - 1)\tau), \dots, x(n)]^T$ und τ einer geeigneten Zeitverzögerung entspricht. Wege werden auf einer Merkmalskarte derart erzeugt, daß ein Bestmatch anhand von $x(n)$ bestimmt wird und $x(n + \tau)$ aus den Gewichten der Merkmalskarte ergänzt wird. Der ergänzte Wert kann dann wiederum als Eingabe zur Bestimmung eines weiteren Bestmatch verwendet werden, so daß zeitlich aufeinanderfolgende Bestmatches als ein Weg dargestellt werden können. In Lin et al. (1997) werden Neuronenaktivitäten im Kortex eines Affens während einer kreisenden Armbewegung gemessen. Dabei dienen die Spikes der feuernden Neuronen von 81 Zellen des Kortex als Eingabe für eine SOM. Diese werden anhand der bekannten Bewegungsrichtungen klassifiziert und als Wege auf einer Merkmalskarte dargestellt. Verschiedene Trajektorien von Armbewegungen eines Affen konnten verschiedenen Wegen auf einer Merkmalskarte zugeordnet werden.

Für die bisher beschriebenen Probleme reicht eine Darstellung von Wegen ohne eine zusätzliche Visualisierung der angelernten Netzstrukturen aus, da bereits a priori eine Klassifikation der Eingabevektoren existiert. Somit können Klassengrenzen auf einer Merkmalskarte "per Hand" eingezeichnet werden (s. Abb.49 und Abb.52). Die Interpretation von Wegen auf SOM ist jedoch mit Schwierigkeiten verbunden, falls kein a priori Wissen über Klassenzugehörigkeiten vorhanden ist. Zur Interpretation von Wegen auf SOM können z.B. bestimmte Heuristiken verwendet werden [Kohonen 88]. Eine andere Möglichkeit besteht darin, große Abstände zwischen zeitlich aufeinanderfolgende Bestmatches als einen Übergang zwischen zwei Klassen zu interpretieren [Behme et al. 93]. Der wesentliche Nachteil beider Ansätze besteht darin, daß die angelernten Netzstrukturen bei der Interpretation von Wegen nicht berücksichtigt werden. Zum Beispiel darf ein Übergang zwischen zwei Bestmatches, die zwar auf einer Merkmalskarte weit auseinander liegen, dennoch in ein und dieselbe Klasse gehören, nicht als ein Übergang zwischen zwei verschiedenen Klassen interpretiert werden. Ein solcher Fall wird durch die bisherigen Ansätze zur Interpretation von Wegen nicht erkannt. Erst durch eine Visualisierung der angelernten Netzstrukturen z.B. durch U-Matrizen können Klassen und Übergänge zwischen Klassen erkannt werden.

Häufig eingesetzte Visualisierungstechniken zur Darstellung der Netztopologie von KNN wie z.B. dreidimensionale Darstellungen von Netzverbindungen bzw. Hintondiagramme [Zell 94] eignen sich nicht zur Visualisierung von SOM, da bei

SOM die Netztopologie bzw. Neuronenaktivitäten durch die Bestimmung eines Bestmatches bekannt sind. Wesentliches Ziel bei der Visualisierung von SOM ist nicht die Interpretation der Aktivität einzelner Neuronen oder Gewichte, sondern die Gewinnung von Informationen über die emergenten Eigenschaften einer großen Anzahl von Neuronen. Verschiedene Visualisierungstechniken für SOM wie z.B. dreidimensionale Gitterstrukturen oder dreidimensionale vektorielle Darstellungen von Fehlern [Ritter et al. 92] geben zwar Aufschluß über die Entwicklung von SOM während des Lernens, jedoch nicht über die zugrundeliegenden strukturellen Eigenschaften von SOM. Zur Erkennung von Strukturen in hochdimensionalen Daten mit Hilfe von SOM eignen sich im wesentlichen zwei Visualisierungstechniken. Es handelt sich dabei um Komponentenkarten und um U-Matrizen.

Bei Komponentenkarten wird die Ausprägung eines Merkmals auf einer Merkmalskarte graphisch dargestellt (s. Abb.50). Die dabei erzeugten Komponentenkarten werden beispielweise zur Prozeßüberwachung eingesetzt [Tryba/Goser 91, Kasslin et al. 92, Kohonen 95]. In Tryba/Goser (1991) wurden beispielsweise Komponentenkarten zum Monitoring einer chemischen Destillationskolonne eingesetzt. Für alle Parameter wie z.B. Temperatur und verschiedene chemische Substanzen werden Komponentenkarten erzeugt. Ein Prozeß kann anhand von Wegen auf den verschiedenen Komponentenkarten beobachtet werden, wobei zur Analyse des Prozesses die Positionen der Bestmatches zu einem bestimmten Zeitpunkt auf allen Komponentenkarten interpretiert werden müssen.

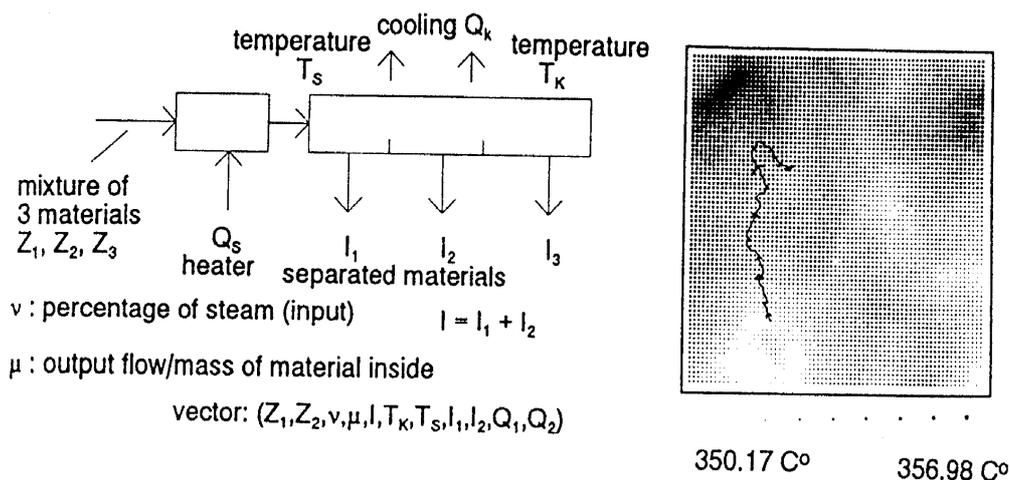


Abb.50: Chemische Destillationskolonne und Weg auf einer Komponentenkarte für die Temperatur (in [Tryba/Goser 91]).

Wesentlicher Nachteil von Komponentenkarten ist jedoch, daß jede Komponente einzeln betrachtet wird. Dadurch kann ggf. der Einfluß jeder einzelnen Komponente auf einen Prozeßzustand erkannt werden, jedoch können die Zusammenhänge zwischen verschiedenen Komponenten nur schwer festgestellt werden. Dies gilt insbesondere dann, wenn hochdimensionale Daten betrachtet werden und dadurch eine große Anzahl von Komponentenkarten erzeugt wird.

Im Gegensatz hierzu besitzen U-Matrizen [Ultsch 92] den Vorteil, daß alle Komponenten gleichzeitig auf einer SOM graphisch dargestellt werden und dadurch eine übersichtliche Darstellung eines Prozeßverlaufes auf nur *einer* U-Matrix möglich ist. U-Matrizen wurden bereits erfolgreich zur Entdeckung und Erkennung von Strukturen in verschiedenen Anwendungsbereichen eingesetzt [Ultsch 91, Schweizer et al. 94, Ultsch et al. 95b, Kohonen 95, Kleine et al. 96, Kaski/Kohonen 96, Ultsch et al. 97]. Eine mögliche Alternative zu U-Matrizen sind explorative Verfahren aus der Statistik, wie z.B. hierarchische Clusterverfahren [Gade et al. 94] oder das k-means-Verfahren [Hartigan/Wong 79]. In Ultsch (1993) wurden U-Matrizen erstmalig zur Überwachung und Steuerung von chemischen Prozessen eingesetzt, wobei Prozeßverläufe identifiziert worden sind, die in einen für den Prozeß kritischen Zustand gelangen. Verschiedene Prozeßzustände wurden hier anhand einer U-Matrix identifiziert (s. Abb.51).

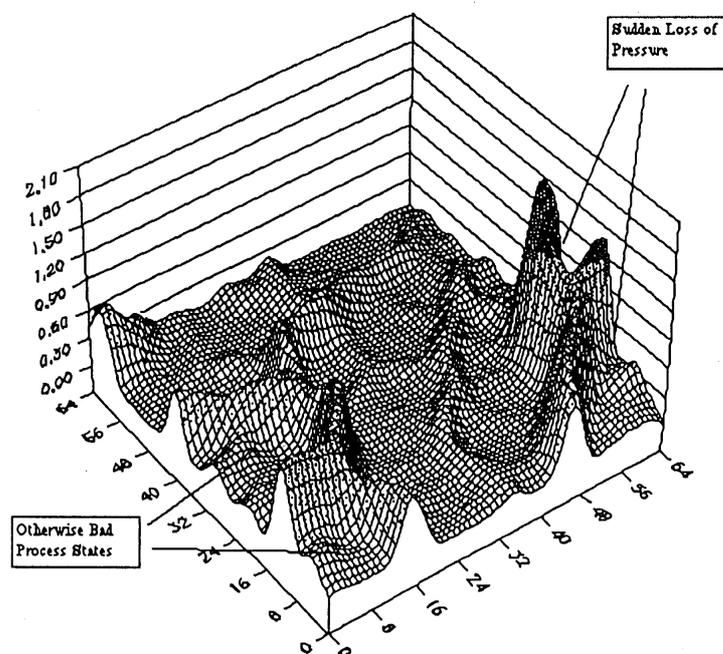


Abb.51: U-Matrix zur Überwachung und Steuerung von chemischen Prozessen (in [Ultsch 93]).

Bisher wurden die verschiedenen Möglichkeiten zur Visualisierung und Interpretation von zeitlichen Verläufen auf SOM vorgestellt. Eine weitere Möglichkeit zur Verarbeitung von Zeit mit SOM besteht darin, Änderungen des Lernalgorithmus [Ritter/Kohonen 89, Kohonen 91, Ichiki et al. 91, Kangas 92, Midenet/Grumbach 94, Ultsch et al. 96, Röske 97] oder der Netztopologie [Tavan et al. 90, Kemke/Wichert 93, Koh et al. 95] vorzunehmen. Bei dem ersten Ansatz wird ein Lernvektor in zwei Teile zerlegt, so daß beim Lernen ein zeitlicher oder sprachlicher Kontext berücksichtigt wird. Erste Ansätze zur Realisierung der Idee des Kontextes liegen in der Sprachverarbeitung [Ritter/Kohonen 89, Ichiki et al. 91, Kangas 92]. Wörter, die Namen von Tieren entsprechen, werden derart kodiert, daß ein Eingabevektor aus einer 0-1-Kodierung eines Tieres und einer 0-1-Kodierung gewonnen aus Attributen bzw. Eigenschaften der Tiere zusammengesetzt ist [Ritter/Kohonen 89]. Da der Teilvektor mit den Attributen stärker gewichtet wird, ordnet sich die Merkmalskarte nach den Attributen der Tiere, so daß ähnliche Tiere auf einer Merkmalskarte nahe beieinander liegen (s. Abb.52). Eine solche Merkmalskarte wird von Ritter/Kohonen (1989) als "semantische Karte" (engl. "semantic map") bezeichnet. Ichiki et al. (1991) fügen zusätzlich eine weitere Schicht mit Neuronen hinzu, die eine Klassifikation der verschiedenen Arten von Tieren enthält. Dadurch kann eine direkte Zuordnung zu den Klassen erfolgen. Diese Ansätze realisieren noch keine Veränderung des Lernalgorithmus.

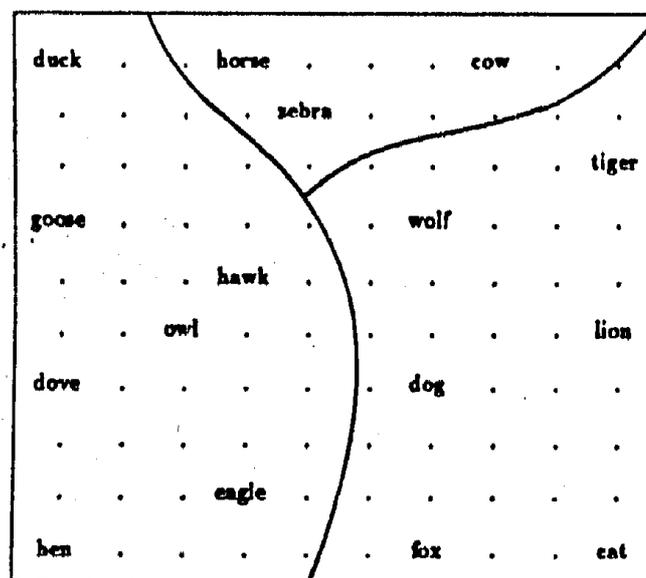


Abb.52: Semantische Merkmalskarte für Namen von Tieren (in [Ritter/Kohonen 89]).

Als erstes wurde die Idee des Kontextes zusammen mit einer Veränderung des Lernalgorithmus von Kohonen (1991) zur Erkennung von Phonemen eingesetzt. Wie auch bei den vorherigen Ansätzen wird der Lernvektor $x = [x_{patt}^T, x_{cont}^T]$ in zwei Teile zerlegt, in einen Teil mit dem Muster x_{patt}^T und in einen Teil mit dem zeitlichen Kontext x_{cont}^T . Die Anpassung der Gewichte erfolgt bei diesem Ansatz in zwei Phasen. In einer ersten Phase wird ausschließlich der Teilvektor mit dem Kontext angelernt. In einer zweiten Phase findet eine Anpassung des Teilvektors mit dem Muster statt. Dabei wird der Bestmatch in einem zweistufigen Prozeß bestimmt. Zuletzt findet ein überwachtes Lernen des Teilvektors mit dem Muster nach dem LVQ Verfahren [Kohonen 84] statt. Eine solche Merkmalskarte wird von Kohonen als "Hypermap" bezeichnet [Kohonen 91]. Eine Veränderung des Kohonen-Lernalgorithmus zu einem überwachten Lernverfahren wird außerdem in der Robotersteuerung eingesetzt [Ritter et al. 89, Ritter et al. 92, Walter/Schulten 93, Heikkonen et al. 93]. Dabei wird der Lernvektor in einen Eingabevektor mit den Bildkoordinaten von zwei Kameras und in einen Ausgabevektor mit den Winkeln eines Roboterarmes zerlegt (s. Abb.53). Zur Bestimmung eines Bestmatches wird während des Lernens nur der Eingabevektor verwendet. Die Anpassung der Gewichte erfolgt getrennt für beide Teilvektoren, den Eingabe- und den Ausgabevektor, wobei hier die Lernrate und der Lernradius für beide Teilvektoren unterschiedlich sein kann.

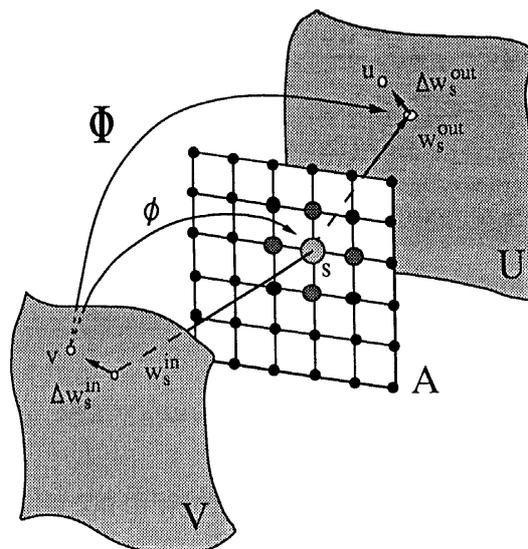


Abb.53: Erweiterte SOM zur Robotersteuerung (in [Ritter et al. 92]).

Im Bereich der Zeitreihenanalyse kann dieser Ansatz zur Vorhersage von Zeitreihen eingesetzt werden [Principe/Wang 95, Ultsch et al. 96, Röske 97]. Hier wird ein Lernvektor in einen Vergangenheits- und in einen Zukunftsvektor zerlegt. Bei Eingabe eines neuen Eingabevektors wird ein Bestmatch auf einer Merkmalskarte anhand des Vergangenheitssteils bestimmt, so daß anschließend eine Vorhersage durch Ergänzung des Zukunftsvektors erfolgen kann. In Principe/Wang (1995) wird dieser Ansatz zur Vorhersage von künstlich erzeugten, nichtlinearen Zeitreihen eingesetzt, wobei eine Vorhersage durch Ergänzung des Zukunftsvektors eines Bestmatches auf einer Merkmalskarte erfolgt. Ein solcher Wert kann nun als Eingabe zur Bestimmung eines nächsten Bestmatches verwendet werden. Weitere Anwendungsgebiete sind die Vorhersage von Hagelgewitter [Ultsch et al. 96] und die Wasserstandvorhersage [Röske 97]. Diese Ansätze unterscheiden sich insofern von dem vorherigen Ansatz, daß hier zunächst eine SOM mit überwachtem Lernverfahren zur Klassifikation von z.B. verschiedenen Hagelgewittertypen eingesetzt wird, um anschließend eine Vorhersage für einen bestimmten Hagelgewittertyp machen zu können. Durch eine Vorklassifikation in z.B. verschiedene Hagelgewittertypen kann eine deutliche Verbesserung der Vorhersagegüte erreicht werden.

Änderungen der Netztopologie von SOM werden dann vorgenommen, wenn weitere Verbindungen zwischen Neuronen hinzugefügt werden wie z.B. bei rekurrenten SOM, oder weitere Schichten hinzugefügt werden wie z.B. bei hierarchischen SOM. Schwierigkeiten bei Einsatz von rekurrenten Netzen liegen darin, daß häufig nur schwer ein stabiler Zustand beim Lernen erreicht werden kann [Tavan et al. 90, So/Chan 94]. Das Problem bei hierarchischen SOM besteht darin, eine geeignete Kodierung der Ausgabe der SOM der unteren Schicht für die Eingabe der SOM der nächsthöheren Schicht zu finden.

Der Einsatz von hierarchischen SOM liegt im Bereich der Bilderkennung [Hung/Lin 94, Koh et al. 95], der Prozeßsteuerung [Weierich/Rosenberg 94], der Spracherkennung [Kemke/Wichert 93, Jiang et al. 94] und der Erkennung von Proteinsequenzen [Andrade et al. 97]. Bei den verschiedenen Ansätzen werden unterschiedliche Kodierungen der Ausgabe der Netze der unteren Schicht vorgenommen. In Koh et al. (1995) werden SOM zur Bildsegmentierung eingesetzt, wobei auf den verschiedenen hierarchischen Ebenen eine Informationsreduktion erfolgt. Dabei wird die Dimension der Merkmalskarten stets verkleinert, so daß die Neuronen auf der SOM der nächst höheren Schichten immer größere Areale eines Bildes repräsentieren. Bei diesem Ansatz wird keine Kodierung der Ausgabe von SOM vorgenommen, sondern die Gewichte der Bestmatches auf einer SOM der unteren Schicht werden lediglich mit den Bestmatches einer SOM der nächst höheren Schicht verbunden. Dieser Ansatz wird auch in Andrade et al.

(1997) zur Erkennung von Familien von Proteinsequenzen verwendet (s. Abb.54).

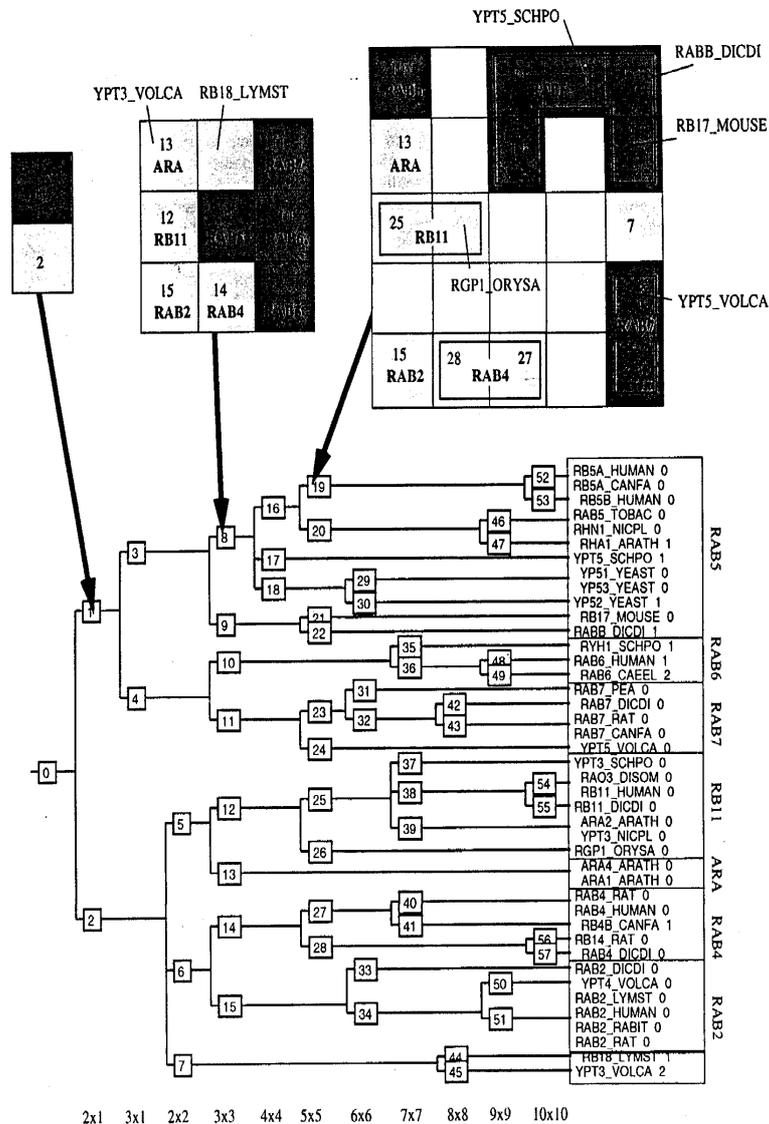


Abb.54: Hierarchische SOM zur Erkennung von Proteinsequenzen (in [Andrade et al. 97]).

In Kemke/Wichert (1993) werden hierarchische SOM zur Spracherkennung eingesetzt, wobei auf den verschiedenen hierarchischen Ebenen immer größere Bestandteile eines Wortes identifiziert werden. Zur Kodierung der Eingabevektoren für die SOM der nächst höheren Schicht wird jedoch die Klassenzugehörigkeit vorausgesetzt. Jedes Neuron auf einer Merkmalskarte wird einer Klasse zugeordnet. Bei Eingabe eines neuen Eingabevektors werden die Gewichte der Neuronen, die eine Klasse auf einer SOM repräsentieren, für alle SOM der unteren Schicht gemittelt. Dieser neuer Gewichtsvektor ist dann die Eingabe für die SOM der

nächst höheren Ebene. Weierich/ Rosenberg (1994) verwenden die Koordinaten der Bestmatches auf den SOM der unteren Ebene als Eingabe für die SOM der oberen Ebene. Eine Transformation der Gewichte eines Neurons der unteren Schicht wird in Jiang et al. (1994) vorgeschlagen. Hierbei wird der Abstand eines Bestmatches zum Eingabevektor berücksichtigt. Bei diesem Ansatz ist ein Neuron mit den Koordinaten (i,j) auf einer SOM einer nächst höheren Schicht mit Neuronen in einer Nachbarschaft um das Neuron mit denselben Koordinaten (i,j) auf der darunterliegenden Schicht verbunden.

In dieser Arbeit wird vorgeschlagen, verschiedene Ansätze zur Verarbeitung von Zeit mit SOM derart zu kombinieren, so daß eine Entdeckung von komplexen Mustern in multivariaten Zeitreihen durch den Einsatz von SOM realisierbar ist. Zur Erkennung von Strukturen in multivariaten Zeitreihen auf verschiedenen Abstraktionsebenen wie z.B. von PrimitivePatterns und Events eignen sich hierarchische SOM. Hierzu wird für jede SOM auf den verschiedenen hierarchischen Ebenen eine U-Matrix erzeugt. Um eine explorative Vorgehensweise auf allen hierarchischen Ebenen zu ermöglichen, wird eine Kodierung von Eingabevektoren für die SOM der nächsthöheren Ebene vorgeschlagen, die die angelernten Netzstrukturen durch eine U-Matrix berücksichtigt. Zeitliche Verläufe wie z.B. Successions und Sequences werden anhand von Wegen auf verschiedenen U-Matrizen beobachtet und interpretiert.

Bei den bisherigen Ansätzen zur Visualisierung von Zeit werden Wege direkt auf einer Merkmalskarte [Kohonen 88, Kohonen 89, Leinonen et al. 92, Utela et al. 92, Leinonen et al. 93, Mujunen et al. 93, Behme et al. 93, Tuya et al. 93, Kita/Nishihawa 93, Kaski/Joutsienimi 93, Joutsienimi et al. 95, Principe/Wang 95, Lin et al. 97] bzw. auf Komponentenkarten [Tryba/Goser 91, Kasslin et al. 92, Kohonen 95] graphisch dargestellt.

Ein wesentlicher Nachteil dieser Ansätze liegt darin, daß hierdurch keine zeitlichen Strukturen entdeckt werden können, sondern diese a priori bekannt sein müssen. Beispielweise treten Schwierigkeiten bei der Interpretation von Wegen auf SOM auf, falls die angelernten Netzstrukturen nicht berücksichtigt werden. Zur Interpretation von Wegen auf SOM werden z.B. von Behme et al. (1993) Abstände zwischen zeitlich aufeinanderfolgenden Bestmatches betrachtet. Hierbei werden große Abstände als ein Übergang zwischen zwei Klassen interpretiert, auch wenn diese ggf. in dieselbe Klasse fallen. Erst durch eine geeignete Visualisierung der Netzstrukturen z.B. durch U-Matrizen können solche Fälle erkannt werden. Die Visualisierung von Netzstrukturen durch Komponentenkarten [Tryba/Goser 91, Kasslin et al. 92, Kohonen 95] eignet sich ebenfalls nicht zur Strukturanalyse, weil hier jede Komponente für sich alleine betrachtet wird. Daher können Zusam-

menhänge zwischen verschiedenen Komponenten nur schwer festgestellt werden. Dies gilt insbesondere, wenn die Komponentenanzahl groß ist.

Bei unserem Ansatz werden zur Entdeckung von Strukturen in Zeitreihen U-Matrizen auf verschiedenen Ebenen einer hierarchischen SOM eingesetzt. Der wesentliche Vorteil unseres Ansatzes liegt darin, daß verschiedene Zustände eines Prozesses mit Hilfe von U-Matrizen entdeckt und Zustandsübergänge durch Beobachtung und Interpretation von Wegen auf U-Matrizen identifiziert bzw. vorhergesagt werden können [Ultsch 93]. Wesentliches Problem bei hierarchischen SOM ist die Kodierung der Eingabevektoren. Bei den bisherigen Ansätzen [Kemke/Wichert 93, Jiang et al. 94, Weierich/ Rosenberg 94, Koh et.al. 95] wird stets eine Klassifikation der Daten vorausgesetzt, so daß hiermit eine Strukturanalyse nicht möglich ist. Daher wird hier vorgeschlagen, die durch eine U-Matrix gewonnene Information über die Netzstruktur zur Kodierung der Eingabevektoren zu verwenden, indem für jede Merkmalskarte die Positionen der Klassenmittelpunkte anhand einer U-Matrix bestimmt und anschließend der Abstand eines Bestmatches von seinem Klassenmittelpunkt für die neu zu berechnende Position des Bestmatches berücksichtigt wird. Dadurch wird eine explorative Vorgehensweise auf allen Ebenen einer hierarchischen SOM ermöglicht.

Da das wesentliche Ziel unseres Ansatzes die Entdeckung von Strukturen in Zeitreihen ist, sind SOM mit überwachtem Lernverfahren, wie sie z.B. zur Vorhersage von Zeitreihen [Principe/Wang 95, Ultsch et al. 96, Röske 97] oder zur Prozeßsteuerung [Ritter et al. 89, Ritter et al. 92] eingesetzt werden, ungeeignet. Eine explorative Vorgehensweise im Sinne einer Strukturanalyse ist hier nicht möglich, da bei diesem Ansatz das Ziel wie z.B. die Vorhersage oder die Position eines Roboterarmes als bekannt vorausgesetzt wird und nicht explorativ entdeckt werden soll.

Obwohl die Entdeckung von zeitlichen Strukturen durch SOM zusammen mit U-Matrizen einen wesentlichen Schritt in einer Strukturanalyse darstellen, wird hierdurch keine inhaltliche Beschreibung der entdeckten Klassen erzeugt. In dieser Arbeit wurde daher zur Beschreibung zeitlicher Strukturen erstmalig der Regelgenerierungsalgorithmus sig* [Ultsch 91] eingesetzt. Der wesentliche Vorteil des Einsatzes eines Regelgenerierungsalgorithmus für die TWK besteht darin, daß nun für eine Anwendung bedeutungsvolle Namen für die entdeckten Strukturen aus den Regeln hergeleitet werden können. Diese Namen können auf höheren Abstraktionsebenen weiterverwendet werden. Erst dadurch erhalten die Regeln einer temporalen Grammatik (TG) eine für die Anwendung interpretierbare und sinnvolle Bedeutung. Für das Anwendungsbeispiel schlafbezogene Atmungsstörungen (SBAS) konnte anhand einer Expertenbefragung gezeigt werden, daß die aus

den sig*-Regeln hergeleiteten Namen durchaus eine für einen Experten der Anwendung interpretierbare und sinnvolle Beschreibung der mit Hilfe von U-Matrizen entdeckten komplexen Muster in multivariaten Zeitreihen geliefert haben.

Um Strukturen in Zeitreihen mit SOM entdecken zu können, werden gewisse Annahmen über die Zeitreihen getroffen (s. Kapitel 3.2). Dadurch ist der Einsatzbereich der TWK auf einen bestimmten Problembereich beschränkt. Es wird angenommen, daß zu entdeckende Strukturen überhaupt in den Daten vorhanden sind. Dies bedeutet, daß unserer Ansatz z.B. zur Verarbeitung von Zeitreihen, die einem reinen Zufallsprozeß entstammen und daher keine relevanten und sich wiederholenden Muster enthalten, eher ungeeignet ist. Außerdem wird bei einer Strukturanalyse vorausgesetzt, daß sich die zu entdeckenden Strukturen häufig genug in den Zeitreihen wiederholen. Diese Voraussetzung ist nicht gegeben, falls nach verhältnismäßig seltenen Ereignissen gesucht wird. Dies kann z.B. bei ökonomische Zeitreihen der Fall sein.

6.2 Symbolische Wissensrepräsentationen für Zeitreihen

Vergleichbare Ansätze zur Repräsentation von Zeit stammen aus einem Bereich der künstlichen Intelligenz (KI), der temporalen Aussagenlogik, und aus dem Bereich der syntaktischen Mustererkennung.

In der temporalen Aussagenlogik wird zwischen der Repräsentation von zeitlichem Wissen an sich und den Verfahren des zeitlichen Schließens unterschieden [Habel et al. 93]. Es existieren grundsätzlich drei Möglichkeiten zur Repräsentation von temporalem Wissen [Vila 94]. Es handelt es sich dabei um Zeitpunkte oder Zeitperioden oder Ereignisse, die als primäre zeitliche Einheiten betrachtet werden. Diese Ansätze finden sich in McDermott's (1982) Punktstrukturen, in Allen's (1984) Intervallstrukturen und in Kowalsky's und Sergot's (1986) Ereignisstrukturen wieder.

Die am häufigsten in der Medizin verwendete Repräsentation von temporalem Wissen sind Intervallstrukturen [Combi/Shahar 97]. Dabei sind Intervallstrukturen eine Verallgemeinerung der von McDermott (1982) eingeführten Punktstrukturen. Bei Punktstrukturen werden zeitliche Einheiten durch eine Menge T von

Punkten repräsentiert, die durch eine Präzedenzrelation geordnet sind. Für die Präzedenzrelation gelten Transitivität und Irreflexivität. Je nach den Anforderungen, die an die Präzedenzrelation gestellt werden, erhält man verschieden starke Systeme der temporalen Logik. Dabei wird unterschieden, ob Zeit in der Vergangenheit und/oder Zukunft gebunden (mit Endpunkten) oder ungebunden (ohne Endpunkten), linear oder verzweigend, diskret, dicht oder kontinuierlich repräsentiert ist. In der Regel wird Zeit als ein linearer, kontinuierlicher und unbegrenzter Zeitstrahl aufgefaßt. Bei dem Ansatz von Allen (1984) liegen zeitliche Einheiten bereits als eine Menge I von Intervallen vor, für die dieselbe Präzedenzrelation und zusätzlich die Inklusion zur Beschreibung von Überlappungen gelten. Für die Inklusion gelten Transitivität, Reflexivität und Antisymmetrie. Zeitpunkte werden dabei als Intervalle aufgefaßt, die nicht weiter in Teilintervalle aufgeteilt werden können. Bei der Überlappungsrelation existieren für Intervalle gemeinsame Teilintervalle, während Präzedenz ohne Überlappung erfolgt. Zur Beschreibung von Überlappungen existieren folgende sich einander wechselseitig ausschließende Relationen zwischen Intervallen (s. Abb.55): Intervalle starten gleichzeitig, Intervalle enden gleichzeitig, ein Intervall ist in dem anderen enthalten, Intervalle folgen direkt aufeinander, Intervalle sind überlappend, Intervalle folgen nach einer Pause aufeinander und Intervalle sind gleichzeitig.

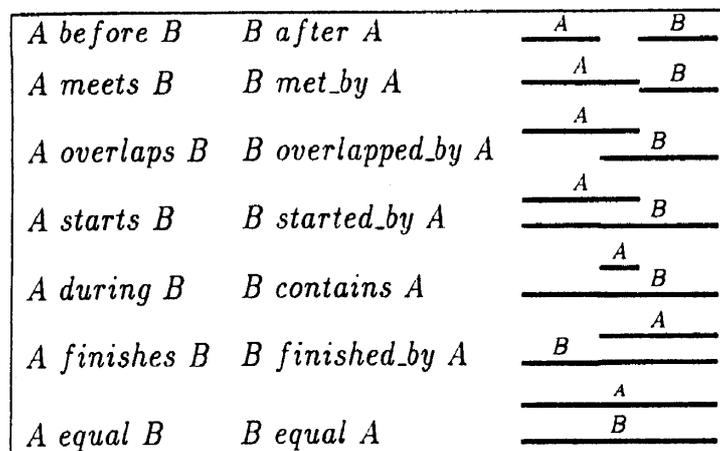


Abb.55: Relationen zwischen Intervallen für Allen's (1984) eingeführte Intervallstrukturen (in [Vila 94]).

Die Anwendungsbereiche für Intervallstrukturen in der Medizin sind vielfältig [Combi et al. 95, Haimowitz/Kohane 96, Siregar/Sinteff 96, Gamper/Nejdl 97, Combi/Shahar 97]. Combi et al. (1995) setzen Intervallstrukturen zur Beschreibung einer Patientendatenbank ein, in der die Daten von Patienten eine zeitliche

Chronologie aufweisen. In solchen Datenbanken werden zeitbezogene Ereignisse äußerst heterogen abgespeichert, so daß Zeit auf unterschiedlichen Zeitachsen wie z.B. Sekunden, Tage, Jahre repräsentiert ist. Zeitliche Abhängigkeiten zwischen Ereignissen werden durch Intervallstrukturen auf verschiedenen Zeitachsen dargestellt. Intervallstrukturen werden außerdem zum Monitoring von Patientendaten wie z.B. Herzfrequenz, mittlerer Blutdruck und Sauerstoffsättigung eingesetzt [Haimowitz/Kohane 96]. Trendänderungen in den Zeitreihen werden bei diesem Ansatz durch Intervallstrukturen beschrieben, wobei Muster in Trends identifiziert werden (s. Abb.56). Diese werden zu diagnostischen Zwecken zur Identifikation von normalen und anormalen Trends eingesetzt.

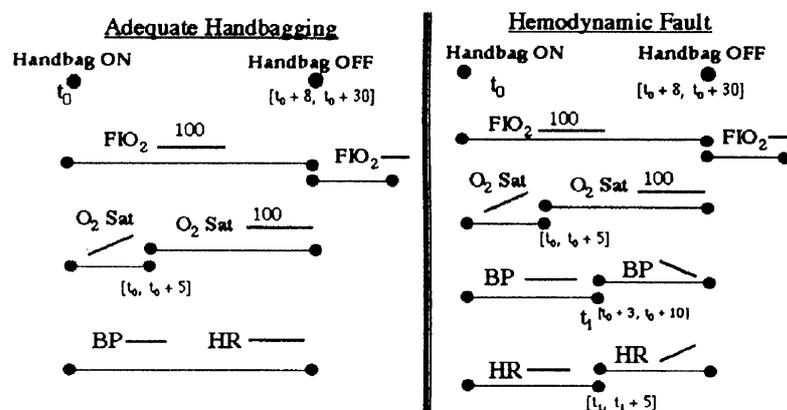


Abb.56: Intervallstrukturen zur Darstellung von Mustern in Zeitreihen (in [Haimowitz/Kohane 96]).

Siregar/Sinteff (1996) verwenden Intervallstrukturen, um zeitliche Abhängigkeiten in EEG Signalen aus verschiedenen Arealen des Gehirns darzustellen und zu simulieren. Hier werden die zeitlichen Relationen zwischen acht verschiedenen Arealen des Gehirns graphisch dargestellt. In Gamper/Nejdl (1997) werden Intervallstrukturen zur Diagnose unterschiedlicher Hepatitis Krankheiten eingesetzt, indem zeitliche Relationen durch temporale Szenarios graphisch dargestellt werden (s. Abb.57).

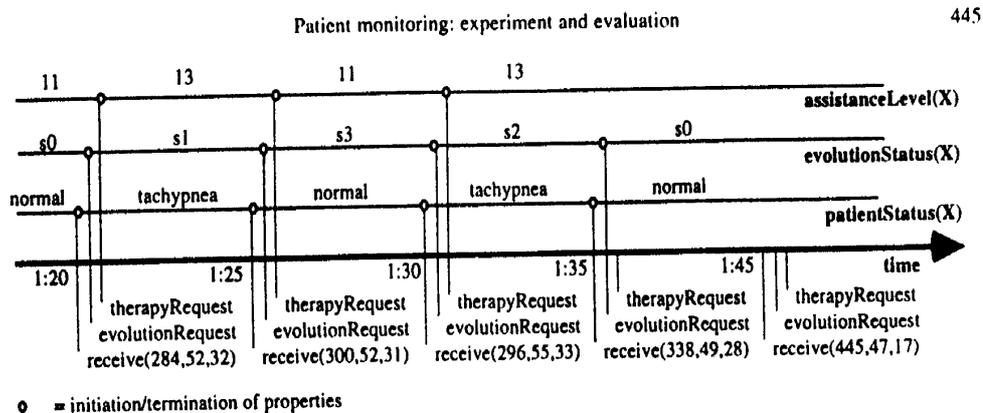


Abb.58: Ereignisse auf verschiedenen Ebenen (in [Chittaro/Dojat 97]).

Ein weiterer vergleichbarer Ansatz zur Darstellung von Zeit stammt aus der syntaktischen Mustererkennung. Hier werden komplexe Muster in Zeichenfolgen grammatikalisch beschrieben. Entsprechen Zeichenfolgen primitiven Mustern, so können diese ggf. anhand ihrer statistischen Eigenschaften identifiziert werden [Kanal/Dattatreya 92, Fukunaga 90]. Komplexe Muster werden dann durch strukturelle und / oder hierarchische Beziehungen zwischen primitiven Mustern beschrieben [Niemann 90]. Anwendungsbereiche für Methoden der syntaktischen Mustererkennung sind u.a. die natürliche Spracherkennung [Bolc 87, Beardon et al. 91, Suppes et al. 96], die Beschreibung von kausalen und temporalen Abhängigkeiten in Patientendatenbanken [Müller et al. 96], die Erkennung von DNA Sequenzen [Searls 95], die Identifizierung von Proteinstrukturen [Conklin 95] und die strukturelle Beschreibungen von Zeitreihen wie z.B. Augenbewegungen [Juhola/Grönfors 91 Juhola 91], EKG Signale [Koski et al. 95] und der Pulsschlag von Halsschlagadern [Bezdek 95].

Bei der Erkennung und Beschreibung von DNA-Sequenzen sowie von Proteinsequenzen durch Grammatiken wird bereits von bekannten primitiven Mustern wie z.B. Aminosäuren bei Proteinsequenzen oder Nukleotiden bei DNA-Sequenzen ausgegangen. In Searls (1995) wird eine Erweiterung von Definitive Clause Grammatiken zur Beschreibung von DNA Sequenzen, sog. String Variable Grammatiken, vorgestellt. Bei diesem Ansatz werden diverse biologische Mutationsoperationen wie z.B. Verdoppelung von Teilsequenzen, Löschen und Einfügen von DNA Nukleotiden, Punktmutationen syntaktisch beschrieben. Ziel bei der Erkennung von Proteinstrukturen ist die Identifizierung von möglichst ähnlichen Strukturen in Proteinsequenzen. In Conklin (1995) werden strukturelle und rela-

tionale Ähnlichkeiten zwischen Proteinsequenzen in einer logikbasierten Sprache definiert, wobei zur Strukturierung und Beschreibung von verschiedenen Typen von Proteinsequenzen Konzeptrahmen (engl. frames) eingeführt werden.

Im Gegensatz hierzu werden zur syntaktischen Analyse von Zeitreihen primitive Muster aus den Zeitreihen gewonnen. In Juhola/Grönfors (1991) werden zur Gewinnung von primitiven Mustern Augenbewegungen in zwei Zustände klassifiziert. Zustand "a" enthält Zeitausschnitte mit einer Augenbewegungsgeschwindigkeit kleiner als $40^\circ/\text{s}$ und Zustand "b" Zeitausschnitte mit einer Augenbewegungsgeschwindigkeit größer als $40^\circ/\text{s}$. Es werden aus Zeichenfolgen des Typs $b^k a^l b^m$, $k, m > 0, l \geq 0$ Grammatiken erzeugt, so daß zwischen normalen und anormalen Augenbewegungen unterschieden werden kann. Bei der syntaktischen Analyse von Elektrokardiogrammen (EKG) wird von einer Zerlegung des Signals in seine verschiedenen Bestandteile wie z.B. P-Wellen und QRS-Komplexe ausgegangen. In Koski et al. (1995) werden zunächst für Zeitfenster Steigungen der Kurven berechnet und klassifiziert, so daß dadurch eine Folge von primitiven Mustern erzeugt wird. Zur syntaktischen Beschreibung der EKG's werden bei diesem Ansatz attributierte Automaten verwendet. Für jedes einzelne Teilmuster eines EKG wie z.B. einer P-Welle wird ein Automat konstruiert. Zur Erkennung des gesamten Signals werden somit verschiedene Automaten durchlaufen. In Bezdek (1995) wird der Pulsschlag von Halsschlagadern gemessen und die aus einer Zeitreihe bestimmten Zeitfenster in acht verschiedene Wellenformen klassifiziert. Eine Zeitreihe wird somit durch eine Folge von verschiedenen Typen von Wellenformen beschrieben.

Unser Vorschlag für eine symbolische Wissensrepräsentation für Zeitreihen ist im wesentlichen an die von Allen (1984) eingeführten Intervallstrukturen angelehnt. Bei diesem Kalkül werden Intervallstrukturen durch 14 Relationen beschrieben, die eine präzise Beschreibung der Start- und Endzeitpunkte von überlappenden und aufeinanderfolgenden Zeitintervallen liefern. Eine solche präzise Darstellung von Intervallstrukturen ist für Probleme der Mustererkennung eher ungeeignet. Da zur Erkennung und Beschreibung von komplexen Mustern in multivariaten Zeitreihen eine erhebliche Informationsreduktion erforderlich ist und außerdem bei der Aufnahme von Signalen häufig Unsicherheiten auftreten, ist eine unscharfe Darstellung zeitlicher Relationen zweckmäßiger. Aus diesem Grund wird in unserem Ansatz ein Sprachkonstrukt verwendet, das eine vage Simultanität zwischen überlappenden Zeitintervallen beschreibt. Dies führt außerdem zu einer Vereinfachung der Sprachkonstrukte, so daß eine für Menschen verständlichere und besser nachvollziehbare Darstellung von komplexen Mustern in multivariaten Zeitreihen erzeugt wird. Außerdem erleichtert eine unscharfe Darstellung zeitli-

cher Relationen die automatische Gewinnung von temporalem Wissen, da somit die Anzahl unterschiedlicher Fälle reduziert wird.

Am Beispiel von schlafbezogenen Atmungsstörungen (SBAS) wurde anhand einer Expertenbefragung die Verständlichkeit und Verwendbarkeit unserer Sprachkonstrukte für die Anwendung überprüft. Die hier verwendeten Sprachkonstrukte eigneten sich zur Beschreibung von SBAS und entsprachen den Vorstellungen eines Experten der Anwendung zur Beschreibung zeitlicher Phänomene. Nach Meinung des Experten können ggf. zeitliche Schwankungen ignoriert werden, so daß möglicherweise von einer Gleichzeitigkeit ausgegangen werden kann.

Eine präzise Beschreibung von Intervallstrukturen nach Allen (1984) kann sich dennoch für bestimmte Anwendungen [Combi et al. 95, Haimowitz/Kohane 96, Siregar/Sinteff 96, Gamper/Nejdl 97] als geeigneter erweisen, falls eine präzise Darstellung von Intervallgrenzen für die Anwendung von Bedeutung ist. Beispielsweise ist dies bei Datenbankzugriffen oder zum on-line Monitoring von Patientendaten erforderlich, da hier genaue zeitliche Angaben über Patientendaten bzw. eingetretene Änderungen des gesundheitlichen Zustands eines Patienten ausgegeben werden müssen. In Siregar/Sinteff (1996) werden beispielsweise Intervallstrukturen zur Simulation und Beschreibung multivariater Zeitreihen eingesetzt, die durch ein EEG aufgenommen wurden. Der wesentliche Unterschied zu unserem Ansatz besteht darin, daß Muster nicht in den Zeitreihen erkannt und beschrieben werden, sondern ein graphisches Modell in Form eines Szenarios aufgebaut wird, durch das zeitliche Abhängigkeiten zwischen den verschiedenen Arealen des Gehirns dargestellt werden können.

Das Konzept der hier verwendeten vagen Simultanität lehnt sich in gewisser Weise an die von Kowalsky und Sergot (1986) eingeführten Ereignisstrukturen an, durch die eine vage Simultanität zwischen Ereignissen beschrieben wird. Der wesentliche Unterschied zu unserem Ansatz besteht darin, daß hier Zustände, die während eines Intervalls auftreten, nicht durch Ereignisse gestartet bzw. beendet werden. Bei unserem Ansatz ist die Einführung von Ereignissen zur Überführung des Systems in einen neuen Zustand nicht erforderlich. Das zu beschreibende System, in unserem Anwendungsbeispiel ein Patient mit SBAS, gerät ohne ein Ereignis von außen in einen neuen Zustand. Ein Beispiel ist der Übergang von *starker Atmung* in den Zustand *Atmung fällt aus*. Dadurch werden Probleme, die bei Ereignisstrukturen auftreten können wie z.B. die Notwendigkeit der Einführung von sog. "ghost-events" [Chittaro/Dojat 97], vermieden.

Neu bei unserem Ansatz ist die Beschreibung von Alternativen zwischen Zuständen, durch die ähnliche Zustände auf verschiedenen Abstraktionsebenen zusammengefaßt werden können. Dies ist für eine automatische Gewinnung von Regeln aus multivariaten Zeitreihen von Vorteil, da dadurch eine zu starke Aufteilung verschiedener, aber ähnlicher Zustände vermieden wird und diese als eine Einheit zusammengefaßt werden können.

Zur Beschreibung von komplexen Mustern in multivariaten Zeitreihen auf einer symbolischen Ebene werden in dieser Arbeit Grammatiken eingesetzt. Zur Erzeugung einer temporalen Grammatik (TG) werden die durch die TWK erzeugten Zwischenergebnisse sowie spezielle temporale Sprachkonstrukte zur Beschreibung von zeitlichen Abfolgen, von vager Simultanität und von Alternativen verwendet. Nach einem Vorschlag von Ultsch (1996) wurden unifikationsbasierte Grammatiken ausgewählt, da zeitliche Eigenschaften wie z.B. die Dauer in unifikationsbasierten Grammatiken durch Variablen als Nebenbedingung in den Regeln formuliert werden können.

Bisherige Ansätze, die unifikationsbasierte Grammatiken verwenden, werden zur Beschreibung von Zeichenfolgen wie DNA-Sequenzen oder Proteinsequenzen [Searls 95, Conklin 95] eingesetzt, bei denen eine zeitliche Abfolge irrelevant ist. Ansätze aus der syntaktischen Analyse zur Beschreibung von Zeitreihen [Juhola/Grönfors 91, Juhola 91, Koski et al. 95, Bezdek 95] beschränken sich auf univariate Zeitreihen, wie z.B. beim EKG oder beim Pulsschlag einer Halsschlagader. Der wesentliche Vorteil unseres Ansatzes liegt darin, daß zeitliche Abhängigkeiten zwischen ggf. sehr vielen Zeitreihen beschrieben werden können. Hierzu wurde ein spezielles Sprachkonstrukt zur Beschreibung einer vagen Simultanität zwischen verschiedenen Zuständen in Zeitreihen eingeführt.

6.3 Hybride Systeme und temporale Wissenskonversion

Hybride Systeme, die Technologien der Künstlichen Intelligenz (KI) und Künstliche Neuronale Netze (KNN) in einem Gesamtsystem integrieren, können prinzipiell in zwei Typen von Hybriden Systemen (HS) unterschieden werden, den "kooperierenden hybriden Systemen" (KHS) und den "hybriden Systemen mit Wissenskonversion" (HSW) [Ultsch 96]. Es werden jedoch hauptsächlich KHS

eingesetzt [Goonatilake/Khebbal 95]. Diese Autoren unterscheiden zwischen drei verschiedene Typen von KHS. Bei "funktionsersetzenden" HS wird ein wesentlicher funktioneller Bestandteil einer Technologie durch eine andere ersetzt. Ein Beispiel hierfür ist das Ersetzen des Backpropagation Lernalgorithmus durch einen genetischen Algorithmus [Montana/Davis 89]. Die eigentlichen "kooperierenden" HS bestehen aus unabhängigen, in sich geschlossenen Modulen, die durch unterschiedliche Technologien repräsentiert bzw. realisiert werden. Zwischen den einzelnen Modulen findet eine Kooperation statt. "Polymorphe" HS simulieren unterschiedliche Technologien durch ein und dieselbe Technologie. KHS können beispielsweise zur Steuerung [Nauck et al. 94, Bezdeck 95, Foslien/Samad 95] oder im Bereich des Datamining [Kerber et al. 95] eingesetzt werden. Von besonderem Interesse für diese Arbeit sind KHS, durch die eine Integration von KI Technologien wie z.B. Expertensysteme oder Fuzzy-Technologien und KNN realisiert wird. In Honavar/Uhr (1995) werden Vor- und Nachteile beider Technologien aufgezeigt, wobei durch eine Integration die Nachteile beider Ansätze aufgehoben werden können.

Folgende Ansätze sind Beispiele für KHS. In Tirri (1995) werden Bedingungen in Regeln eines Expertensystems durch einzelne Neuronen, sog. "pattern nodes", eines KNN mit überwachtem Lernverfahren ersetzt. Bei diesem Ansatz findet eine neuronale Kodierung eines oder mehrerer Symbole durch ein Neuron statt. Ein ähnlicher Ansatz wird in Ajjanagadde/Shastri (1995) zur Variablenbindung eines in Prolog implementierten Expertensystems verwendet, indem Variablen lokal durch einzelne Neuronen kodiert werden. Klimasauskas (1995) führt zur Diagnose komplexer chemischer Prozesse wie z.B. die Herstellung von Polyethylen eine Fuzzyifizierung der gemessenen Werte durch, um diese als Eingabe für ein KNN mit überwachtem Lernverfahren zu verwenden. Ziel ist es hier, eine bessere Trennbarkeit der Klassen zu erreichen. In Scherer/Schlageter (1995) wird ein KHS zur Vorhersage ökonomischer Zeitreihen vorgestellt. Auf einer symbolischen Ebene kann ein Benutzer Anfragen über bestimmte vorherzusagende Werte wie z.B. Arbeitslosigkeit stellen. Die Vorhersage wird dann durch ein KNN durchgeführt. Die Ausgabe des Ergebnisses erfolgt wiederum auf einer symbolischen Ebene.

Bei dem anderen Typ von HS, den "hybride Systemen mit Wissenskonzersion" (HSW) [Ultsch 96], findet stets ein Übergang zwischen subsymbolischer und symbolischer Wissensrepräsentation statt. Ein Beispiel hierfür ist das im Rahmen eines BMBF-Projektes entwickelte WINA¹-System [Ultsch 93a, Palm et al. 94, Ultsch 95a]. In dem WINA-System werden verschiedene Technologien wie spe-

1. Wissensverarbeitung in neuronalen Architekturen

zielle KNN mit unüberwachtem Lernverfahren, Assoziativspeicher, Regelgenerierungsalgorithmen und Expertensysteme in einem Gesamtsystem integriert. In den KNN wird eine subsymbolische Wissensrepräsentation von hochdimensionalen Daten erzeugt. Diese wird in eine symbolische Wissensrepräsentation in Form von Regeln durch den Einsatz des Regelgenerierungsalgorithmus sig* [Ultsch 93a] überführt. Das WINA-System wurde zunächst anhand von medizinischen Daten wie z.B. Eisenmangelkrankheiten und Azidose getestet [Ultsch 91]. Weitere Einsatzgebiete des WINA-Systems sind die Diagnose von Lawinengefahrstufen [Schweizer et al. 93], die Klassifikation und Beschreibung von Meeressedimenten [Ultsch et al. 95b] und die Liquoranalyse [Kleine et al. 96, Ultsch et al. 97].

Durch den Einsatz von HSW kann ein spezielles Problem bei der Konstruktion von Expertensystemen angegangen werden. Es handelt sich dabei um das Problem der Wissensakquisition. In der KI wird als Wissensakquisition die Formulierung von Expertenwissen für ein Expertensystem bezeichnet [Puppe 91, Wachsmuth 93]. Die Wissensakquisition wird sogar oftmals als "das" zu lösende Problem bei der Konstruktion von Expertensystemen bzw. wissensbasierten Systemen angesehen [Cimino/Barnett 93, Andrews 95]. Außerdem wird Wissensakquisition als das schwierigste und aufwendigste Problem bei der Konstruktion von Expertensystemen betrachtet [Scott et al. 91, Sestito/Dillon 94]. Hierzu können beispielsweise Regelgenerierungsalgorithmen eingesetzt werden [Ultsch 91, Wachsmuth 93, Ohmann et al. 95]. Eine mögliche Alternative zu dem in dieser Arbeit eingesetzten Regelgenerierungsalgorithmus sig* sind Regelgenerierungsalgorithmen wie z.B. NewId, CN2, C4.5, CART [Ohman et al. 95, Blazadonakis et al. 96, Cooper et al. 97].

Ziel einer Wissensakquisition ist es, Expertenwissen derart zu erfassen, daß es zum einen maschinell weiterverarbeitet werden kann und zum anderen möglichst umfassend und vollständig ist. Dieser Prozeß kann u.U. für große Wissensbasen mehrere Jahre oder sogar Jahrzehnte andauern [McDermott/Bachant 84]. Häufig werden zur Wissensakquisition Werkzeuge zur interaktiven Wissensakquisition geschaffen [Bürsner et al. 95]. In der Regel sind jedoch Experten durch ihre täglichen Aufgaben so stark ausgelastet, daß sie selten für die Konstruktion von Expertensystemen von ihren Aufgaben freigestellt werden können. Wäre dies dennoch der Fall, so ist das aus Erfahrungen gewonnene Wissen häufig nur schwer kommunizierbar und in regelhaftes Wissen überführbar. Werden Experten aufgefordert, Regelmäßigkeiten darzustellen, so werden in der Regel entweder außergewöhnliche Fälle oder sehr allgemeine Zusammenhänge beschrieben, für die viele Gegenbeispiele, also Ausnahmen von der Regel, existieren. Oft wird vom Experten anhand von Assoziationen nach ähnlichen Fällen gesucht. Ein neuer Fall wird in Analogie zu bereits bekannten Fällen behandelt. Dies legt den Einsatz von KNN

zur Wissensakquisition nahe, die aus Beispielen lernen können und wie ein assoziatives Gedächtnis funktionieren.

Bei den meisten Ansätzen zur automatischen Regelgewinnung aus KNN werden Regeln in einem überwachten KNN derart kodiert, daß Bestandteile der Regeln bereits durch einzelne Neuronen auf einer symbolischen Ebene repräsentiert sind [Andrews et al. 95]. Hier existiert kein Übergang zwischen verschiedenen Wissensrepräsentationsformen. Durch den Einsatz von KNN mit unüberwachtem Lernverfahren wie z.B. den Selbstorganisierenden Merkmalskarten nach Kohonen (1984), bei denen eine verteilte Repräsentation eines Sachverhaltes in einer subsymbolischen Wissensrepräsentation erzeugt wird, kann ein Übergang zwischen subsymbolischer und symbolischer Wissensrepräsentation stattfinden [Ultsch 91].

Die in dieser Arbeit entwickelte Methode zur temporalen Wissenskonversion (TWK) gehört in die Klasse der "hybriden Systeme mit Wissenskonversion". Auf den durch die TWK eingeführten Abstraktionsebenen erfolgt u.a. durch den Einsatz von speziellen KNN mit unüberwachtem Lernverfahren ein Übergang von multivariaten Zeitreihen in eine temporale, symbolische Wissensrepräsentation. Dadurch entsteht eine neue Qualität der Wissenskonversion, die in dieser Arbeit als temporale Wissenkonversion bezeichnet wird. Mit Hilfe der TWK kann ggf. das Problem der Wissensakquisition für einen speziellen Problembereich angegangen werden, wobei hier komplexe Muster in multivariaten Zeitreihen in eine für Menschen interpretierbare und für Maschinen verarbeitbare Form überführt werden können. Es handelt sich dabei um einen neuartigen Ansatz, wie es ihn bisher in dieser Art und Weise für multivariate Zeitreihen noch nicht gibt.

Dennoch können mit Hilfe der TWK nicht alle möglichen Probleme der Zeitreihenanalyse bearbeitet werden. Der Ansatz ist auf bestimmte Anwendungsbereiche eingeschränkt. Er eignet sich beispielsweise nicht zur Vorhersage von Zeitreihen, bei denen eine möglichst hohe Vorhersagegüte erzielt werden soll [Weigend/Gershenfeld 94]. Außerdem eignet sich die TWK nicht für Probleme, bei denen ein qualitativer Sprung zwischen verschiedenen Wissensrepräsentationen nicht erforderlich ist. Beispiel hierfür sind hybride Systeme, bei denen eine Kooperation zwischen in sich geschlossenen, unabhängigen Modulen stattfindet [Goonatilake/Khebbal 95] und bei denen Symbole wie z.B. Variablen in einem Neuron bereits auf einer symbolischen Ebene kodiert werden [Tirri 95, Ajjanagade/Shastri 95].

Kapitel 7

Zusammenfassung und Ausblick

Es war Ziel dieser Arbeit, in multivariaten Zeitreihen durch den Einsatz von künstlichen neuronalen Netzen (KNN) mit unüberwachtem Lernverfahren komplexe Muster zu entdecken und diese in eine für Menschen interpretierbare wie auch für Maschinen verarbeitbare Wissensrepräsentation zu überführen. Dieses Ziel wurde dadurch motiviert, daß die den Zeitreihen zugrundeliegenden Prozesse häufig noch für die Anwendung unbekannte Zusammenhänge enthalten, die ggf. durch eine explorative Methode entdeckt werden können. Um die entdeckten komplexen Muster beurteilen zu können, wird in dieser Arbeit deren Überführung in eine symbolische, für Menschen interpretierbare und kommunizierbare Wissensrepräsentation vorgeschlagen. Dabei werden die einzelnen Meßwerte als eine subsymbolische Wissensrepräsentation von Zeitreihen aufgefaßt. Der Übergang zwischen verschiedenen Wissensrepräsentationen für multivariate Zeitreihen wird als temporale Wissenskonversion bezeichnet. Die in dieser Arbeit entwickelte Methode zur temporalen Wissenskonversion (TWK) wurde auf ein nicht triviales Beispiel aus der Medizin angewendet. Die Ergebnisse dieser Anwendung wurden anhand eines eigens für eine Expertenbefragung erstellten Fragebogens evaluiert. Es zeigte sich, daß durch den hier verfolgten Ansatz komplexe Muster entdeckt und für einen Experten der Anwendung sinnvoll beschrieben werden können. Insbesondere wurden Hinweise auf "neu" entdecktes Wissen gefunden.

Mit Hilfe der TWK kann eine zunehmende Abstraktion von Zeitreihen im Sinne einer "gleitenden" temporalen Wissenskonversion erfolgen. Durch die eingeführten hierarchischen Abstraktionsebenen wird das schwierige Problem der temporalen Wissenskonversion in eine Abfolge technisch behandelbarer Teilaufgaben zerlegt. Es wird hiermit eine „Brücke“ zwischen subsymbolischer und symbolischer Wissensrepräsentation für multivariate Zeitreihen geschlagen.

Zur Entdeckung von Strukturen in Zeitreihen sind KNN betrachtet worden, die sich durch Selbstorganisation an die strukturellen Eigenschaften von hochdimensionalen Daten anpassen können. Es handelt sich dabei um die selbstorganisierenden Merkmalskarten nach dem Modell von Kohonen (1984). Erst durch eine geeignete Visualisierung der angelernten Netzstrukturen z.B. durch U-Matrizen ist eine Strukturerkennung überhaupt möglich. Bisherige Einsatzbereiche zur Strukturerkennung mit SOM und U-Matrizen beschränken sich im wesentlichen auf zeitunabhängige Daten [Ultsch 91, Ultsch et al. 97, Kaski/Kohonen 96, Kaski 97].

Ein Anliegen dieser Arbeit war es, unterschiedliche Ansätze von SOM zur Verarbeitung von Zeit derart zu kombinieren, daß eine Entdeckung von komplexen Mustern in multivariaten Zeitreihen realisierbar ist. Dabei werden die in multivariaten Zeitreihen auftretenden komplexen Muster als unbekannt angenommen. Voraussetzung ist jedoch, daß solche Muster in den Zeitreihen überhaupt vorkommen. Um dies zu gewährleisten, werden gewisse Annahmen über die zu verarbeitenden Zeitreihen getroffen.

Die wesentliche Idee war dabei der Einsatz von U-Matrizen auf verschiedenen Ebenen einer hierarchischen SOM und die Interpretation von zeitlichen Verläufen durch Wege auf U-Matrizen. Mit Hilfe von U-Matrizen sollen einerseits Strukturen in Zeitreihen auf verschiedenen hierarchischen Ebenen entdeckt werden und andererseits Zustandsübergänge durch Beobachtung und Interpretation von Wegen auf U-Matrizen identifiziert bzw. vorhergesagt werden. Um eine explorative Vorgehensweise auf allen hierarchischen Ebenen zu ermöglichen, wurde eine Kodierung der Eingabevektoren für die SOM der nächsthöheren Ebene vorgeschlagen, die die angelernten Netzstrukturen und deren U-Matrix berücksichtigt. Bisherige Ansätze zur Visualisierung von Zeit durch Wege auf SOM berücksichtigen die angelernten Netzstrukturen nicht oder nur unzureichend, so daß bei diesen Ansätzen die Entdeckung von Strukturen in Zeitreihen nicht möglich ist. Dasselbe gilt für die Kodierung von Eingabevektoren in hierarchischen SOM, bei denen eine Klassenzugehörigkeit stets vorausgesetzt wird.

Neben der Entwicklung einer Methode zur temporalen Wissenskonversion war ein weiteres Ziel dieser Arbeit das Finden einer symbolischen Wissensrepräsentation für komplexe Muster in multivariaten Zeitreihen. Da Sprache in welcher Form auch immer die am weitesten verbreitete und natürlichste Darstellung von Wissen ist, wurden Grammatiken als Wissensrepräsentationsform gewählt. Es wurden unifikationsbasierte Grammatiken verwendet, da sie Vorteile bzgl. Repräsentation und Verarbeitung von Zeit aufweisen [Ultsch 96b]. Im Zusammenhang mit der TWK werden solche Grammatiken als temporale Grammatiken (TG) be-

zeichnet. Wesentlicher Bestandteil von TG sind spezielle temporale Sprachkonstrukte. Zur Konstruktion einer TG werden zudem die mit Hilfe der TWK gewonnenen Zwischenergebnisse eingesetzt. Außerdem hat sich der Einsatz von Regelgenerierungsalgorithmen zur symbolischen Beschreibung elementarer zeitlicher Strukturen als vielversprechend erwiesen. Die aus den Regeln hergeleiteten Namen werden in einer TG verwendet. Damit wird eine für die Anwendung bedeutungsvolle Beschreibung von komplexen Mustern auf verschiedenen Abstraktionsebenen erzeugt.

Unser Ansatz lehnt sich an die von Allen (1984) eingeführten Intervallstrukturen an, die eine präzise Darstellung der Start- und Endzeitpunkte von überlappenden und aufeinanderfolgenden Zeitintervallen liefern. Zur Beschreibung von komplexen Mustern in multivariaten Zeitreihen hat sich jedoch eine Betrachtung von vager Simultanität zwischen Zeitintervallen als zweckmäßiger erwiesen. Zwar lehnt sich das Konzept der vagen Simultanität an die von Kowalsky und Sergot (1986) eingeführten Ereignisstrukturen an. Dennoch wird bei unserem Ansatz das Eintreten von Zuständen nicht durch Ereignisse ausgelöst. Unser neues Konzept zur Beschreibung von Intervallstrukturen führt außerdem zu einer Vereinfachung von Sprachkonstrukten, so daß dadurch sowohl eine für Menschen interpretierbare und verständlichere Darstellung erzeugt wird als auch die Gewinnung von TG erleichtert wird. Neu bei unserem Ansatz ist die Beschreibung von Alternativen, durch die ähnliche Zustände auf verschiedenen Abstraktionsebenen der TWK zusammengefaßt werden können.

Die TWK kann in die Klasse von "hybriden Systemen mit Wissenskonzersion" [Ultsch 96] eingeordnet werden. In hybriden Systemen werden Technologien der künstlichen Intelligenz (KI) und KNN in ein Gesamtsystem integriert, so daß die Nachteile beider Technologien aufgehoben werden können. Dabei werden "hybride Systeme mit Wissenskonzersion" weitaus seltener eingesetzt als hybride Systeme, bei denen lediglich eine Kooperation zwischen unabhängigen, in sich geschlossenen Modulen stattfindet.

Mit Hilfe der TWK läßt sich das Problem der Wissensakquisition für Zeitreihen angehen. Wissensakquisition wird oftmals als "das" zu lösende Problem bei der Konstruktion von Expertensystemen angesehen. Erschwerend sind dabei die Verfügbarkeit von Experten, die häufig durch ihre täglichen Aufgaben stark ausgelastet sind, und die Schwierigkeiten bei der Formulierung von Expertenwissen. Die TWK kann als ein erster Schritt hin zu einer automatischen Gewinnung von temporalem Wissen betrachtet werden.

Zur Anwendung und Prüfung der TWK wurde ein schwieriges Problem aus der Medizin gewählt. Es handelt sich dabei um schlafbezogene Atmungsstörungen (SBAS). Diese eignen sich als Anwendungsbeispiel, da hier verschiedene Muster von SBAS wiederholt auftreten und erst durch eine parallele Auswertung mehrerer Zeitreihen identifiziert werden können. Die gute Qualität der gemessenen Zeitreihen und die langjährige Erfahrung der Experten waren zusätzliche Kriterien für die Auswahl von SBAS als Anwendungsbeispiel.

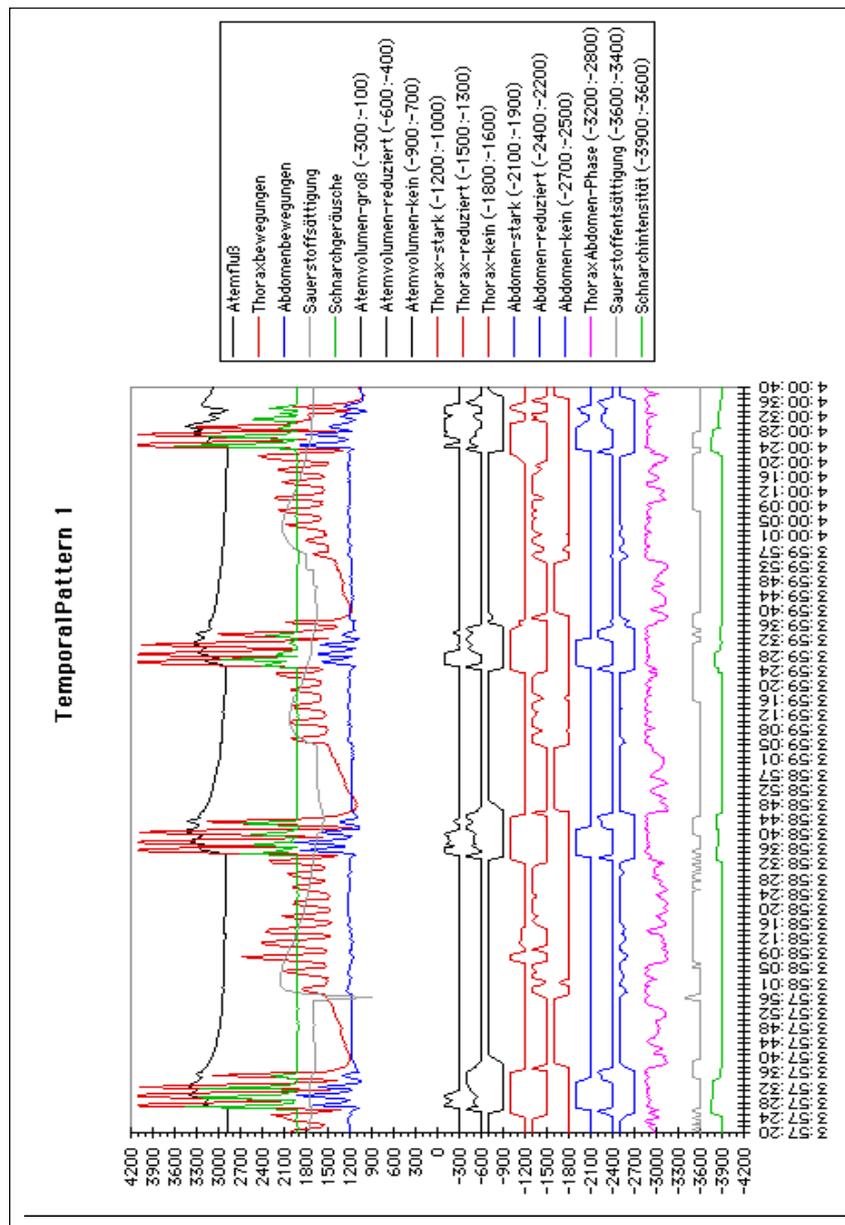
Probleme bei der Auswertung von SBAS sind z.B. sehr unterschiedliche individuelle Muster desselben Typs für verschiedene Patienten, bei denen außerdem die Dauer der Muster stark variieren kann [Penzel 95]. Mit Hilfe der TWK wurden die in den Zeitreihen auftretenden komplexen Muster richtig erkannt und auf einer symbolischen Ebene durch eine TG für einen Experten der Anwendung sinnvoll beschrieben. Zudem wurden Hinweise auf "neu" entdecktes Wissen gefunden. Durch die erfolgreiche Anwendung der TWK auf SBAS konnte gezeigt werden, daß die hier entwickelte Methode durchaus zur Bearbeitung von schwierigen und komplexen Problemen eingesetzt werden kann.

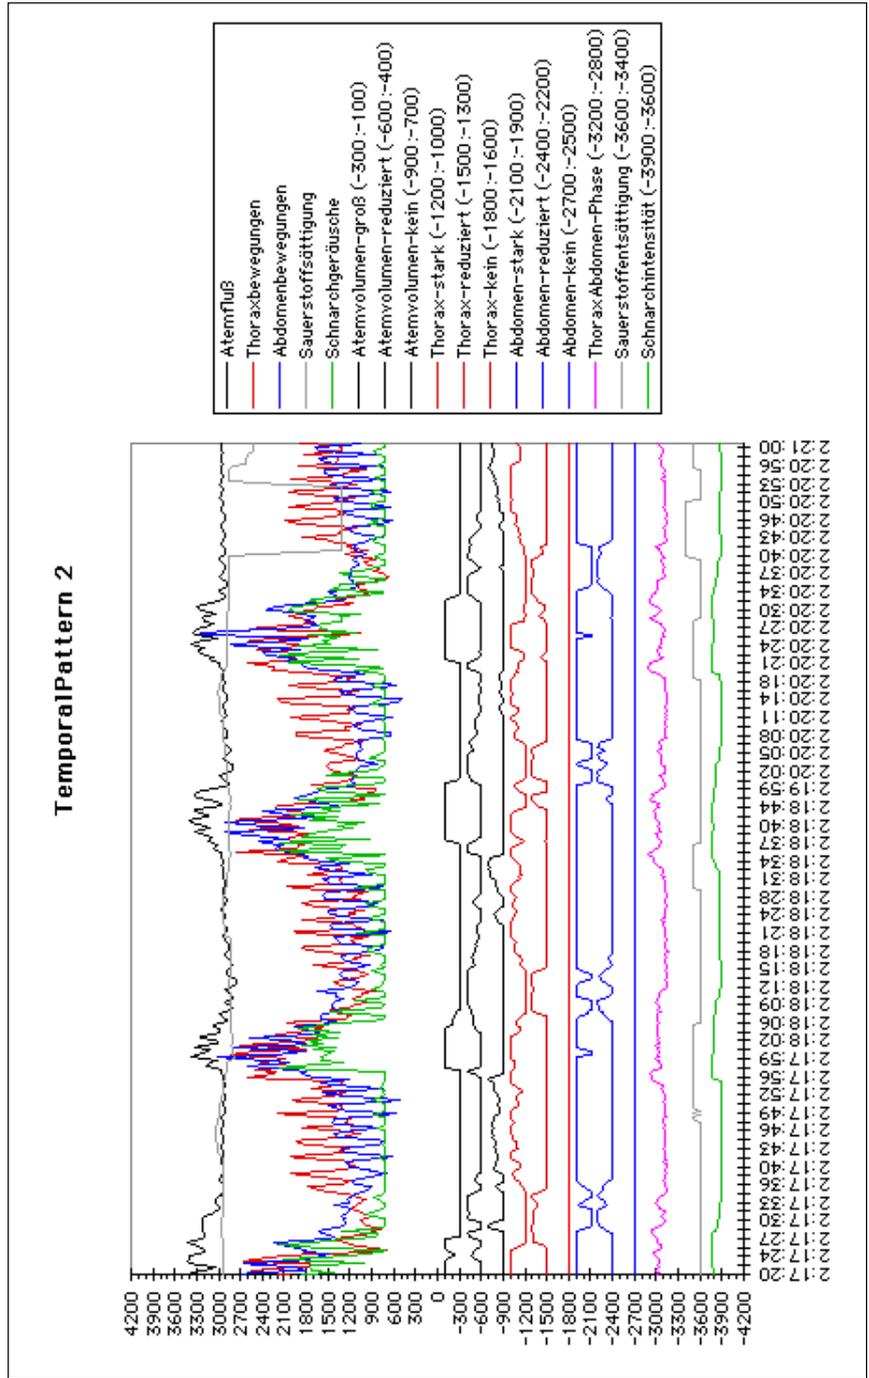
Es handelt sich bei SBAS um ein erstes Anwendungsbeispiel, auf das die TWK angewendet worden ist. Weitere Anwendungsbeispiele wären die Auswertung von Hagelgewitterdaten oder von Daten bei der Stahlerzeugung. Außerdem könnten zusätzlich zu den in dieser Arbeit bearbeiteten atmungsbezogenen Signalen weitere Zeitreihen der kardiorespiratorischen Polysomnographie wie z.B. schlafbezogene und kardiovaskuläre Signale einbezogen werden.

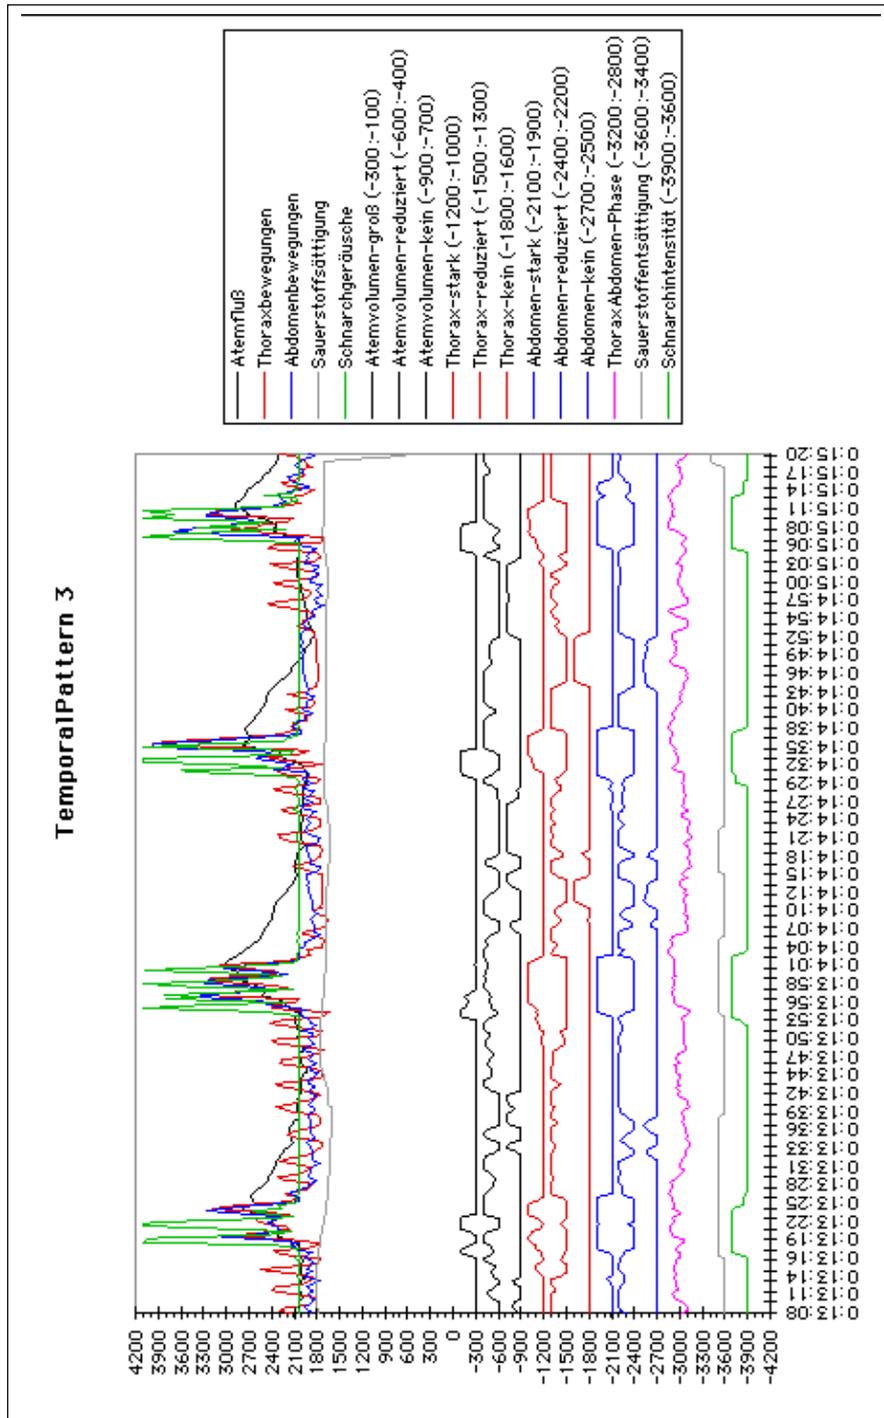
Da es sich bei Zeitreihen um eine sehr große Anzahl von Daten handelt, konnten mit den bisherigen Implementierungen von SOM nur relativ kleine Zeitbereiche angelernt werden. Um größere Zeitausschnitte anlernen zu können, sind viel umfangreichere SOM erforderlich. Vielversprechend ist daher eine parallele Implementierung des Kohonen-Algorithmus für eine entsprechende Rechnerarchitektur wie z.B. einen NCube Parallelrechner. Somit können sehr viel größere SOM in sehr viel kürzerer Zeit angelernt werden.

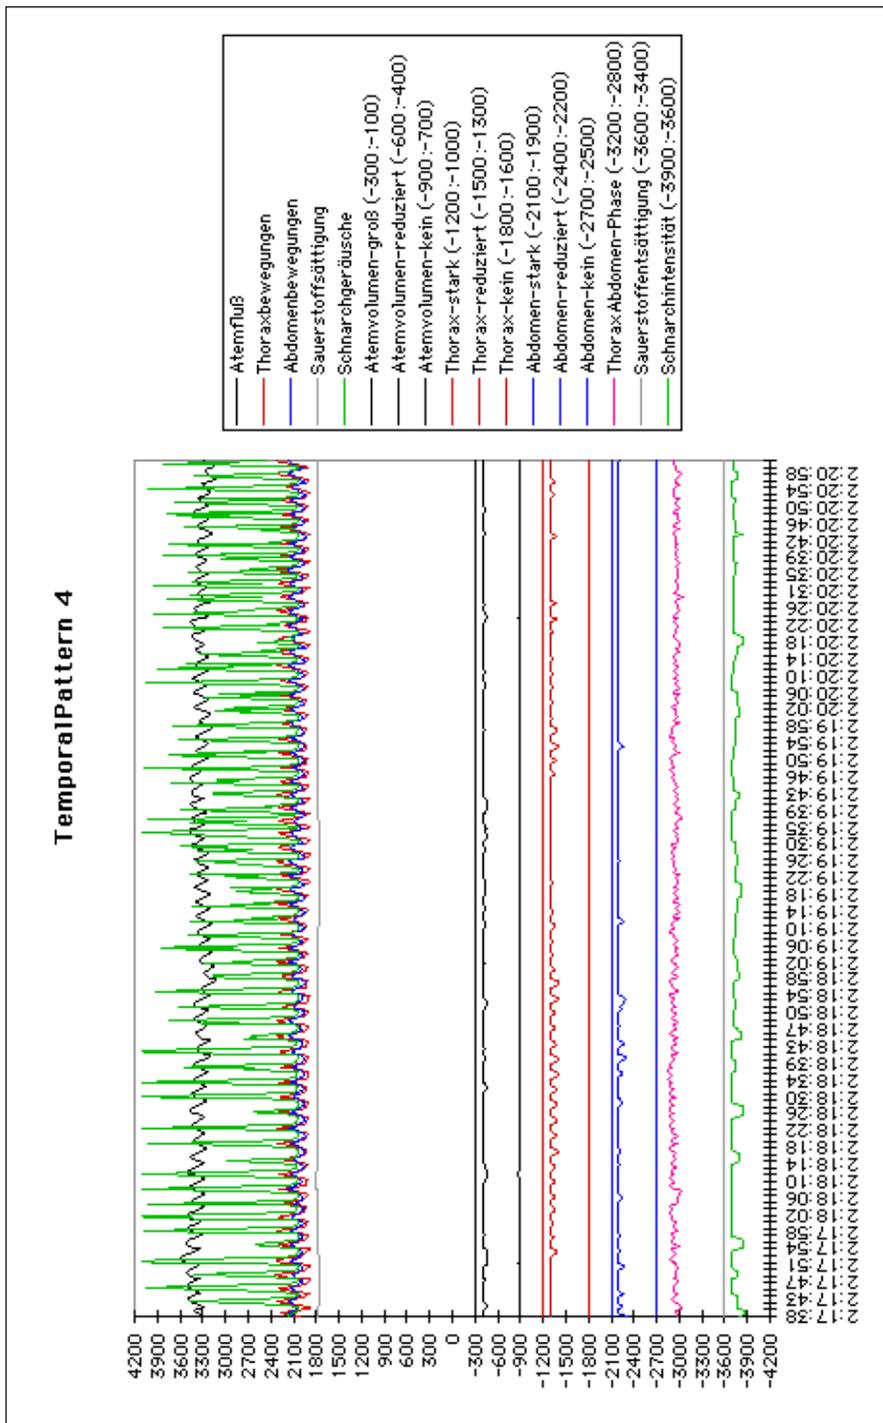
Anhang

A.1 Graphische Darstellung der Merkmale und der Zeitreihen

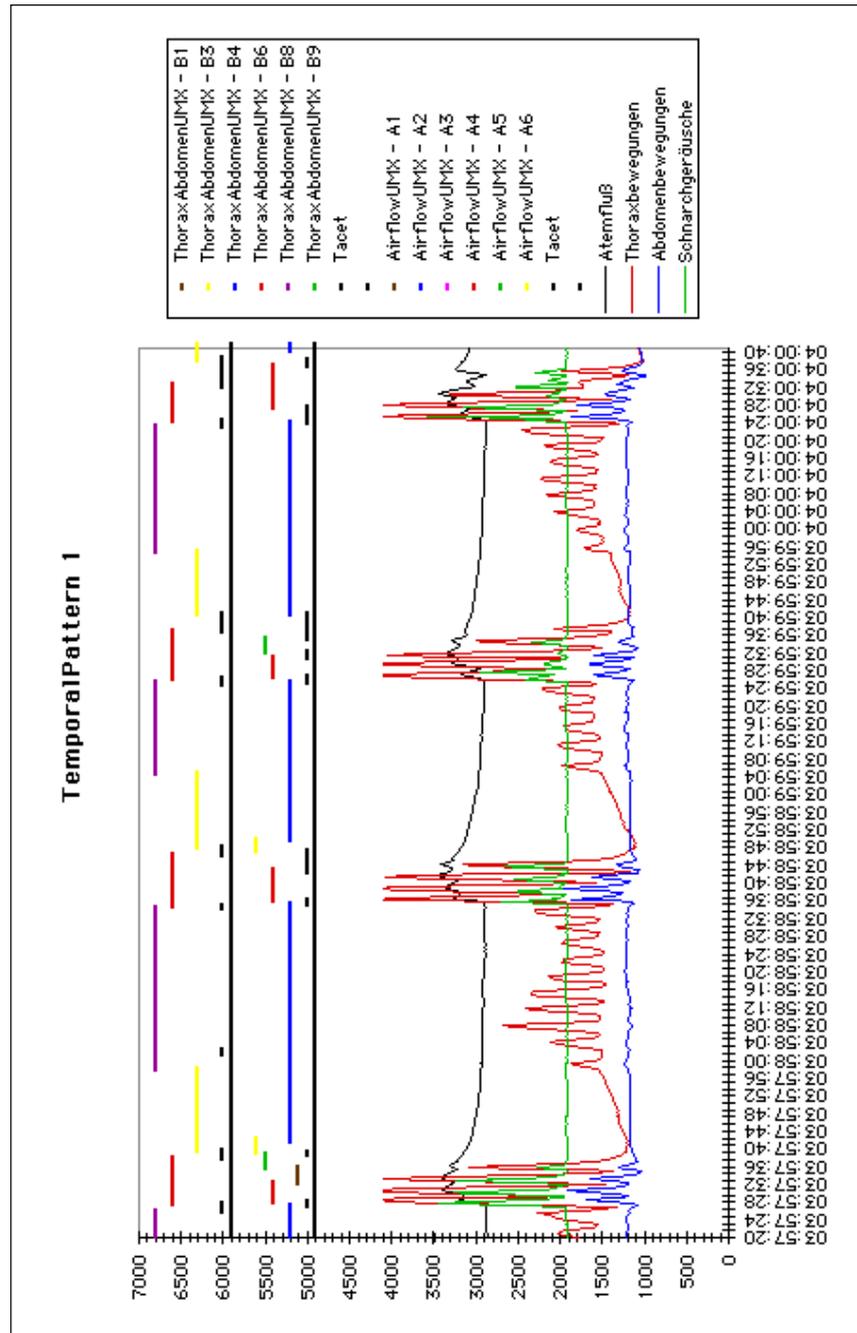


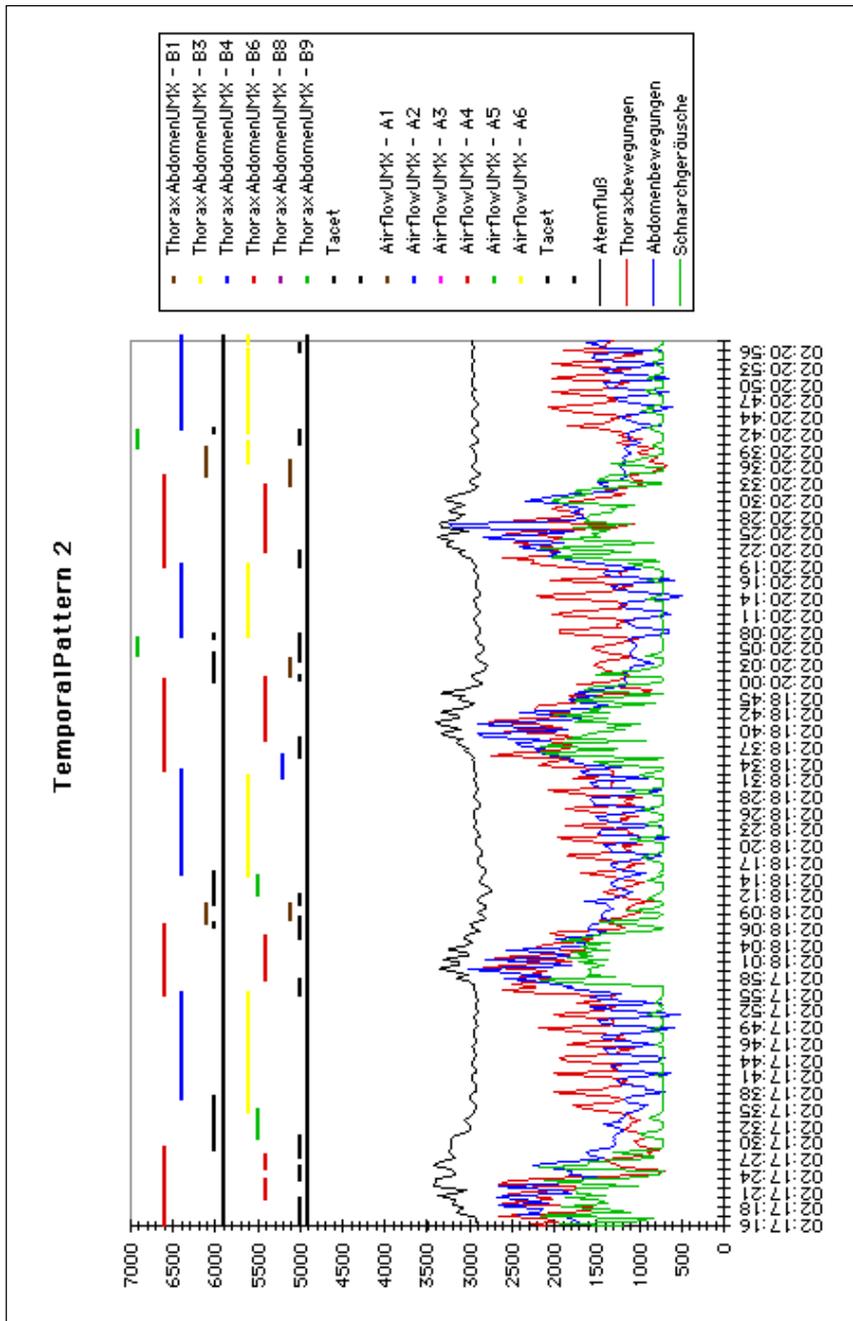


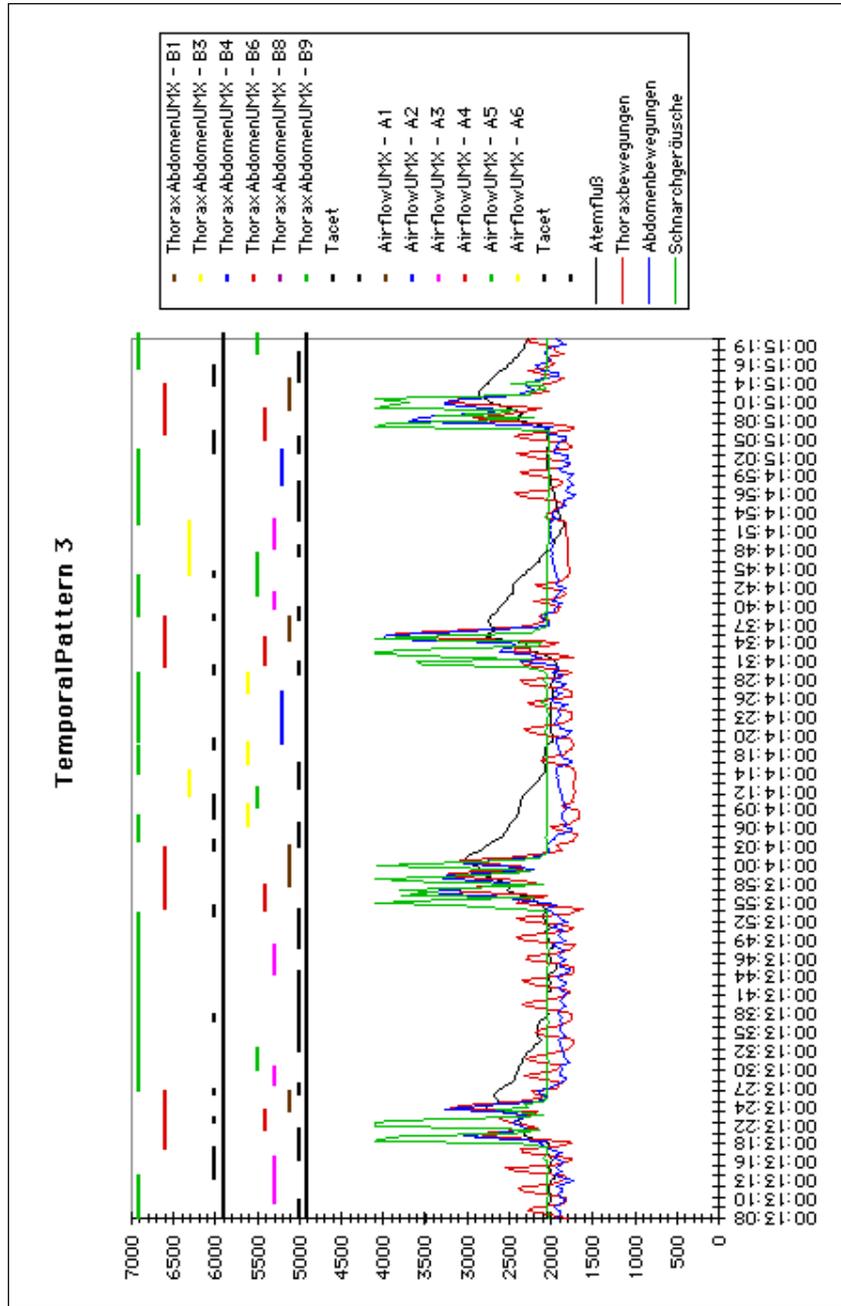


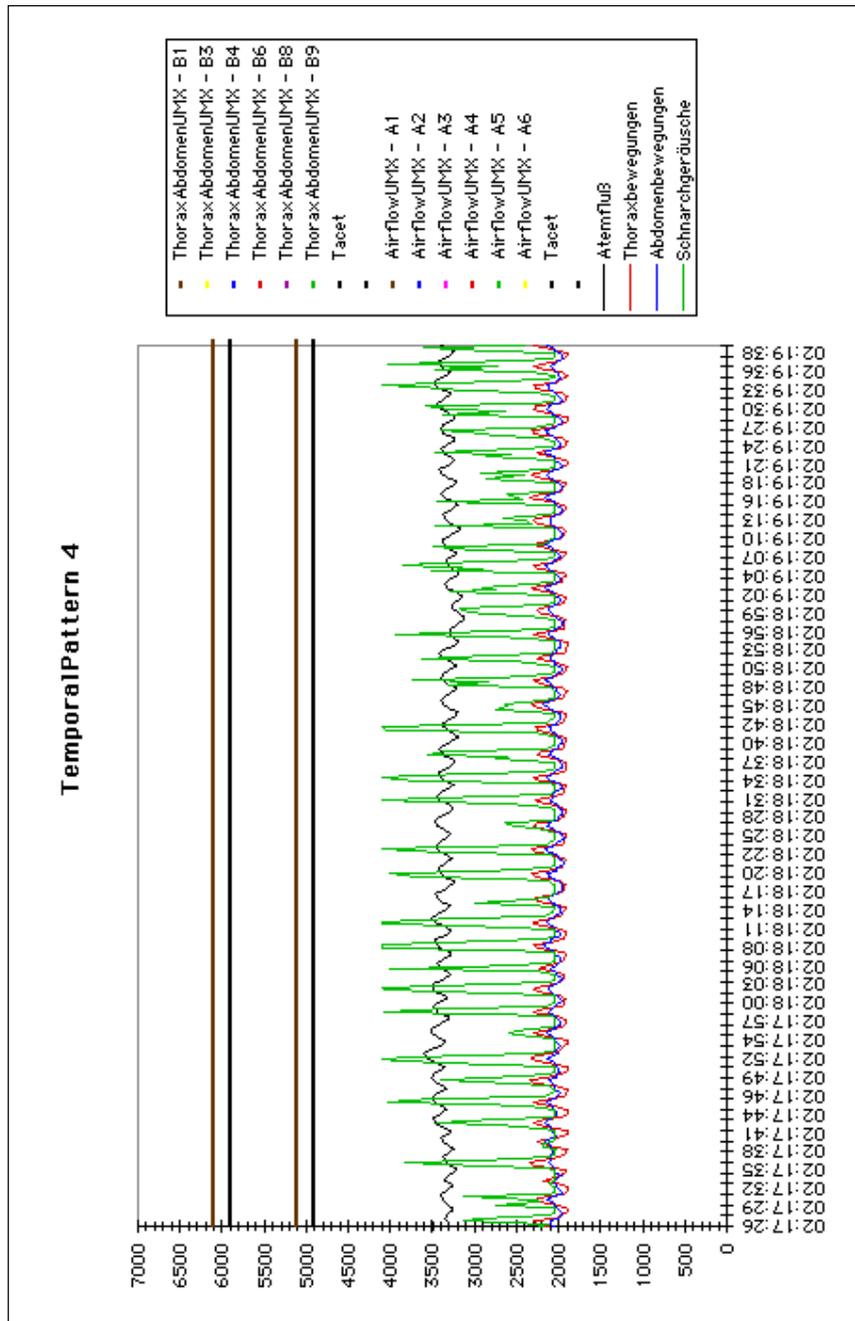


A.2 Graphische Darstellung der Successions für *AirflowUMX* und *ThoraxAbdomenUMX* und der Zeitreihen

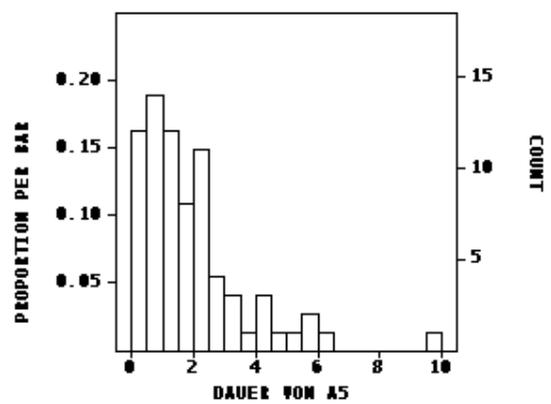
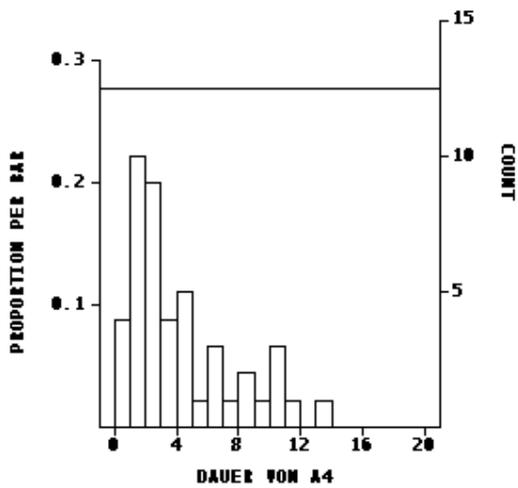
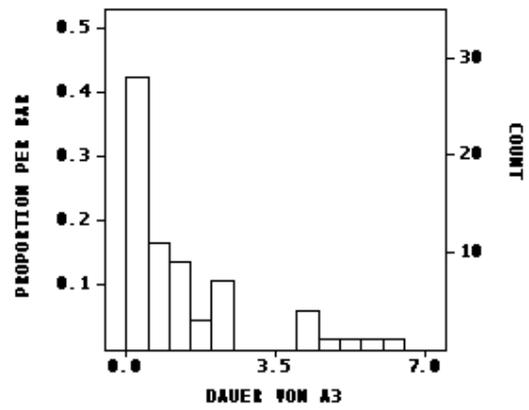
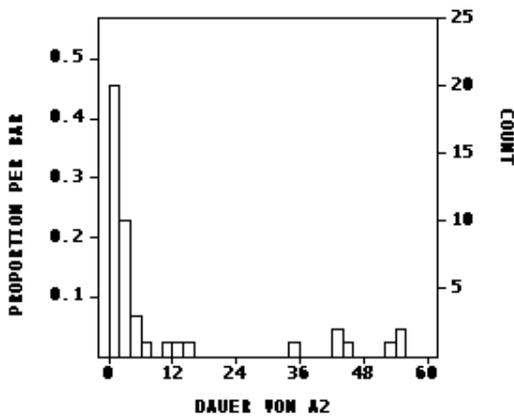
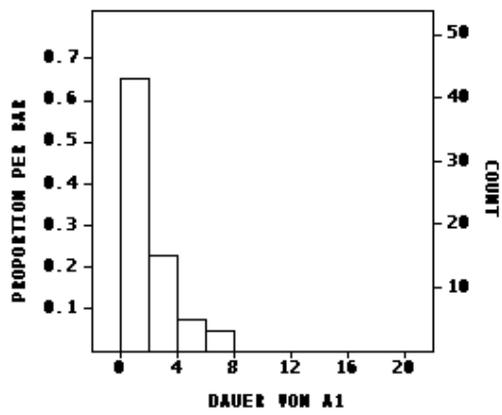
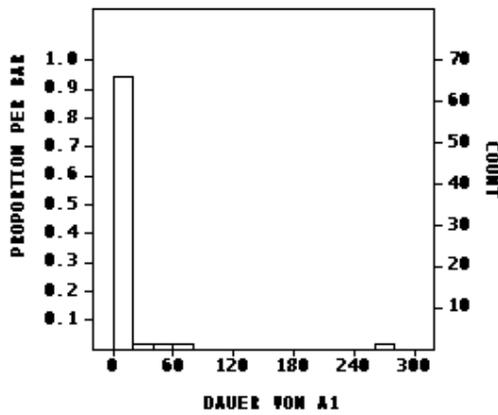


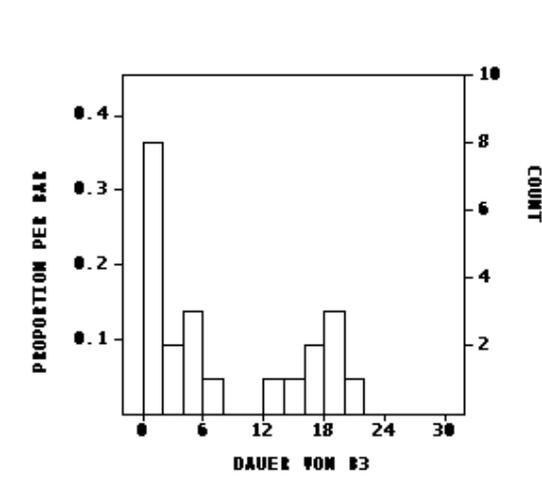
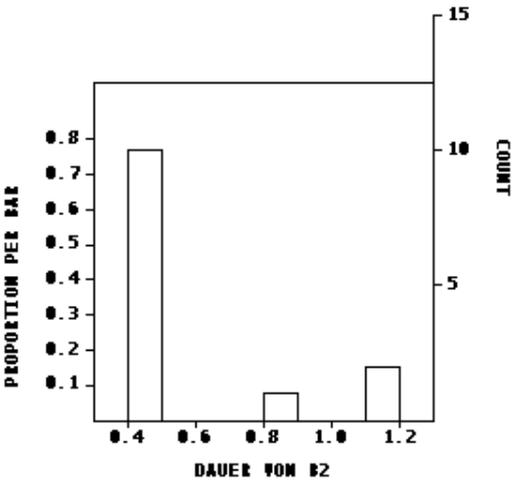
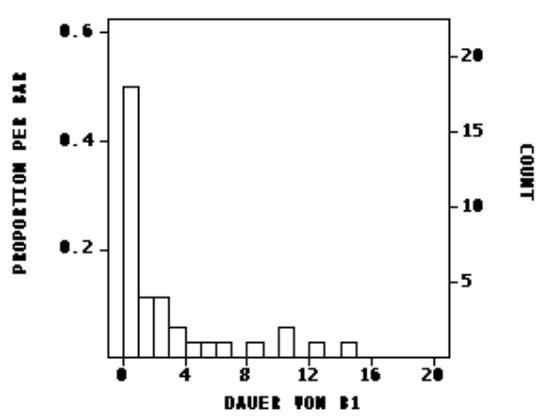
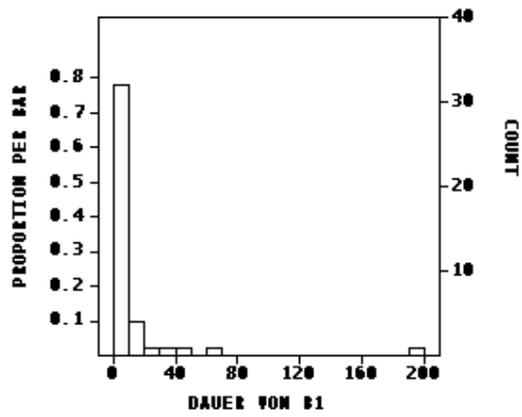
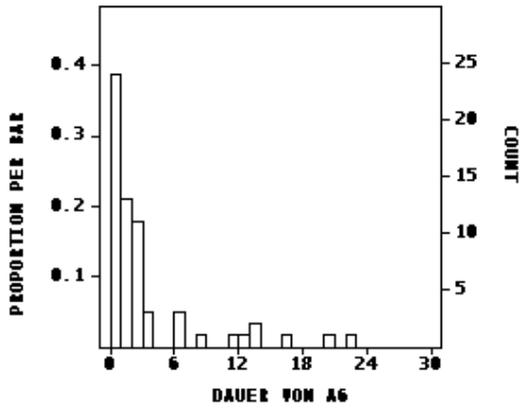


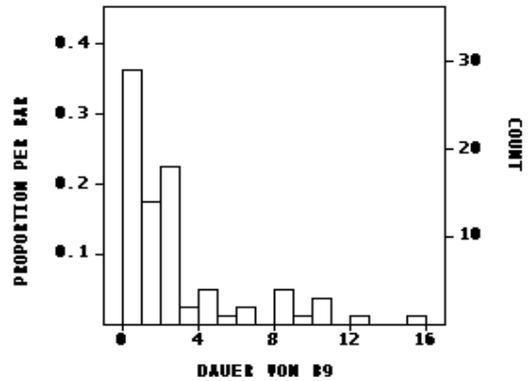
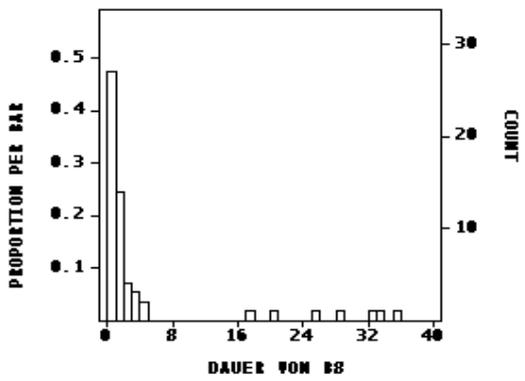
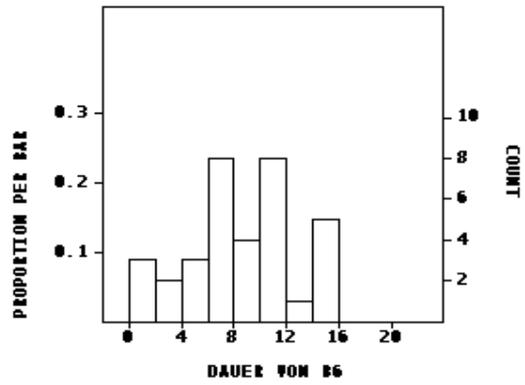
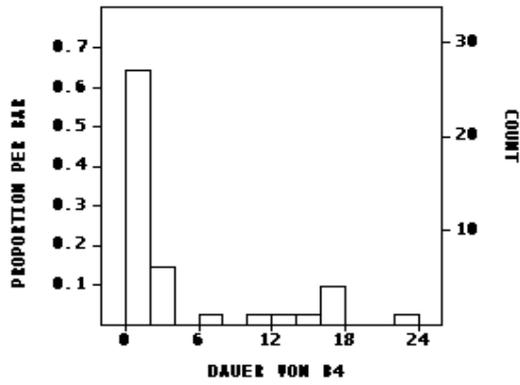




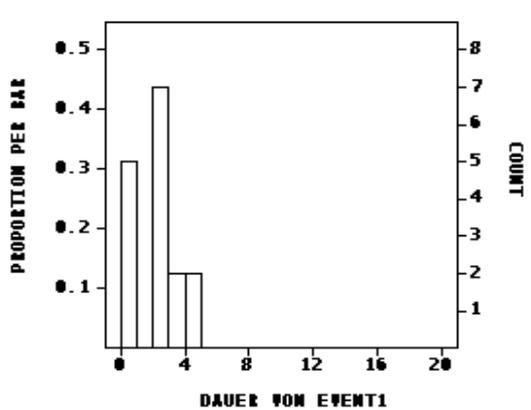
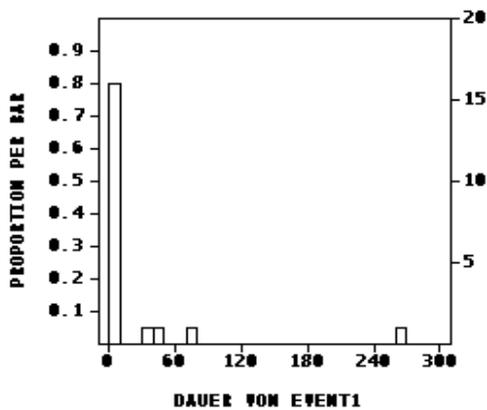
A.3 Histogramme für die Dauer der Successions

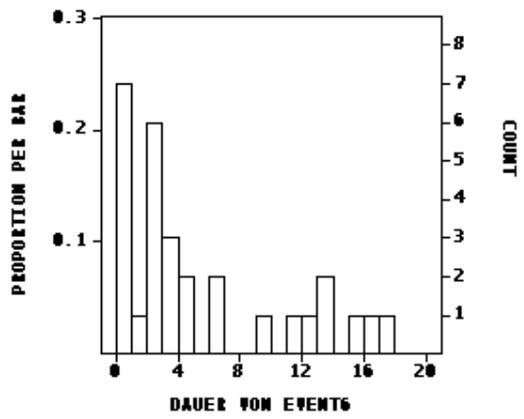
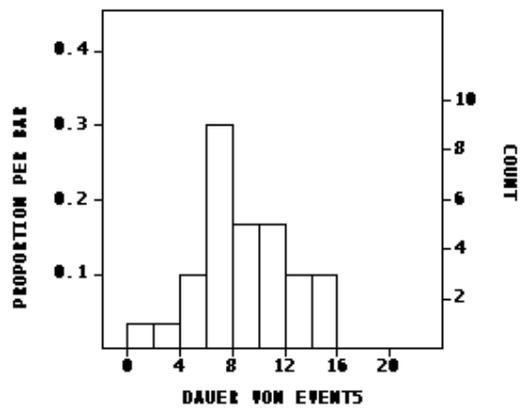
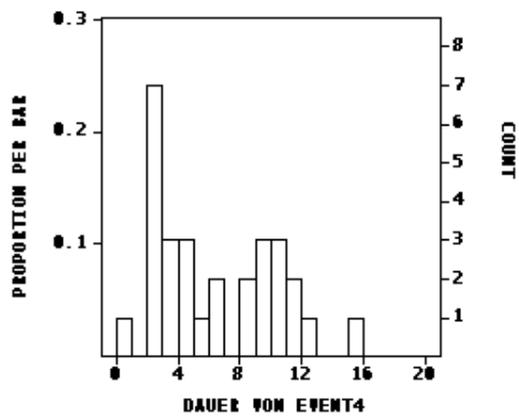
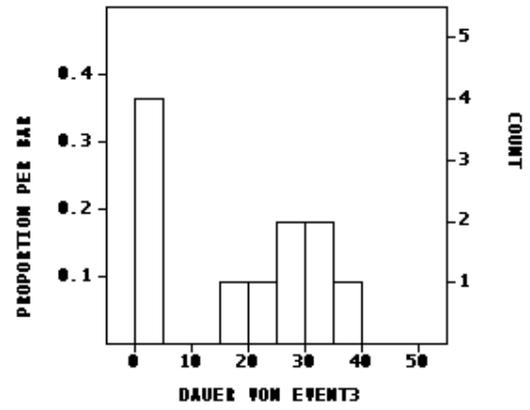
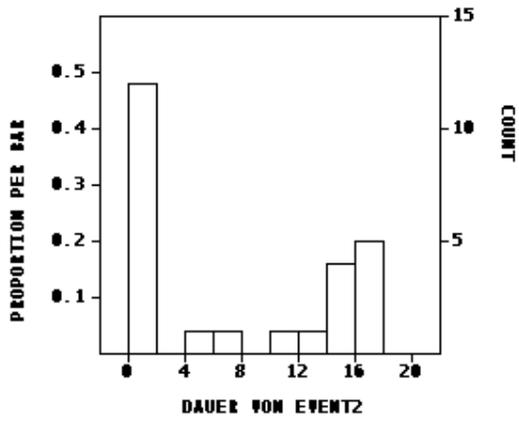






A.4 Histogramme für die Dauer der Events





A.5 Ergebnisse zu den Events

Absolute Häufigkeiten	<i>A1:</i> <i>reAV-</i> <i>mS</i>	<i>A2:</i> <i>keAV-</i> <i>oS</i>	<i>A3:</i> <i>geAV-</i> <i>oS</i>	<i>A4:</i> <i>grAV</i> <i>mS</i>	<i>A5:</i> <i>reAV-</i> <i>oS</i>	<i>A6:</i> <i>geAV-</i> <i>oS</i>	<i>A0:</i> <i>Tacet</i>	Summe
<i>B1:</i> <i>reparTABmS</i>	1038	16	0	0	0	6	5	1065
<i>B3:</i> <i>keTABoS</i>	0	304	14	0	19	22	44	403
<i>B4:</i> <i>gegTAB</i>	0	3	0	0	14	328	16	361
<i>B6:</i> <i>stTAB</i>	108	8	0	382	28	3	160	689
<i>B8:</i> <i>reTBke-</i> <i>ABoS</i>	0	527	0	0	0	4	6	537
<i>B9:</i> <i>repar-</i> <i>gegTABoS</i>	0	56	94	0	46	50	173	419
<i>B0:</i> <i>Tacet</i>	81	72	29	48	77	37	235	579
Summe	1227	986	137	430	184	450	639	4053

Tabelle 10: Absolute Häufigkeit von gleichzeitig auftretenden PrimitivePatterns aus *AirflowUMX* (*Ai*) und *ThoraxAbdomen-UMX* (*Bj*).

PrimitivePatterns der <i>AirflowUMX</i>	PrimitivePatterns der <i>ThoraxAbdomenUMX</i>	Events	prozentuale Übereinstimmung der Merkmale in den sig*Regel
A5	B4	Event 6	71,43%
A5	B9	Event 4	77,78%
A2	B9	Event4	66,66%
A1	B6	Event 5	85,71%
A6	B9	Event 4	88,89%

Tabelle 11: Übereinstimmung der Merkmale in den sig*-Regeln (in Prozent) für die Events ohne Tacet.

A.6 Sig*-Regeln für die PrimitivePatterns

Sig*-Regeln für die PrimitivePatterns der AirflowUMX

Ein PrimitivePattern ist ein 'A1'

falls

und $\text{'Atemvolumen-reduziert'} \in [0.7309, 1]$
 und $\text{'Atemvolumen-kein'} = 0$
 und $\text{'Schnarchintensität'} \in [0.333, 1.0475]$.

Diesem PrimitivePattern wurde der Name *'reduziertes Atemvolumen mit Schnarchgeräusche'* gegeben.

Ein PrimitivePattern ist ein 'A2'

falls

und $\text{'Atemvolumen-kein'} \in [0.9509, 1]$
 und $\text{'Atemvolumen-reduziert'} = 0$
 und $\text{'Schnarchintensität'} \in [-0.0405, 0.2415]$.

Diesem PrimitivePattern wurde der Name *'kein Atemvolumen ohne Schnarchgeräusche'* gegeben.

Ein PrimitivePattern ist ein 'A3'

falls

und $\text{'Schnarchintensität'} \in [-0.0295, 0.254]$
 und $\text{'Atemvolumen-reduziert'} \in [0, 0.673]$
 und $\text{'Atemvolumen-kein'} \in [0, 0.775]$
 und $\text{'Atemvolumen-stark'} = 0$.

Diesem PrimitivePattern wurde der Name *'geringes Atemvolumen ohne Schnarchgeräusche'* gegeben.

Ein PrimitivePattern ist ein 'A4'

falls

und 'Atemvolumen-stark' \in [0.3697, 1]
und 'Atemvolumen-kein' = 0
und 'Schnarchgeräusche' \in [0.15, 1].

Diesem PrimitivePattern wurde der Name '*großes Atemvolumen mit Schnarchgeräuschen*' gegeben.

Ein PrimitivePattern ist ein 'A5'

falls

und 'Atemvolumen-reduziert' \in [0.737, 1]
und 'Atemvolumen-kein' = 0
und 'Schnarchintensität' \in [-0.009, 0.1725].

Diesem PrimitivePattern wurde der Name '*reduziertes Atemvolumen ohne Schnarchgeräusche*' gegeben.

Ein PrimitivePattern ist ein 'A6'

falls

und 'Atemvolumen-reduziert' \in [0, 0.749]
und 'Atemvolumen-kein' \in [0, 0.727]
und 'Schnarchintensität' \in [-0.028, 0.2195].

Diesem PrimitivePattern wurde der Name '*geringes Atemvolumen ohne Schnarchgeräusche*' gegeben.

Sig*-Regeln für die PrimitivePatterns der ThoraxAbdomenUMX

Ein PrimitivePattern ist ein 'B1'

falls

und	'Abdomen-reduziert'	∈	[0.711, 1]
und	'Thorax-reduziert'	∈	[0.684, 1]
und	'Schnarchintensität'	∈	[0.337, 1.047]
und	'Abdomen-stark'	=	0
und	'Thorax/Abdomen-Phase'	∈	[-0.154, 0.564] .

Diesem PrimitivePattern wurde der Name '*reduzierte parallele Thorax- und Abdomenbewegungen mit Schnarchgeräuschen*' gegeben.

Ein PrimitivePattern ist ein 'B2'

falls

und	'Abdomen-kein'	=	0
und	'Thorax-stark'	=	0
und	'Thorax-reduziert'	∈	[0.469, 1]
und	'Thorax/Abdomen-Phase'	∈	[0.279, 0.788] .

Diesem PrimitivePattern wurde der Name '*reduzierte parallele Thorax- und Abdomenbewegungen*' gegeben.

Ein PrimitivePattern ist ein 'B3'

falls

und	'Thorax-kein'	∈	[0.7725, 1]
und	'Abdomen-kein'	∈	[0.6417, 1]
und	'Thorax-reduziert'	∈	[0, 0.0325]
und	'Schnarchintensität'	∈	[-0.041, 0.0235] .

Diesem PrimitivePattern wurde der Name '*keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche*' gegeben.

Ein PrimitivePattern ist ein 'B4'

falls

und	'Abdomen-stark'	∈	[0.11, 1]
und	'Thorax/Abdomen-Phase'	∈	[-0.715, -0.278]
und	'Abdomen-reduziert'	∈	[0, 0.117]
und	'Thorax-reduziert'	∈	[0, 0.188] .

Diesem PrimitivePattern wurde der Name '*gegenläufige Thorax- und Abdomenbewegungen*' gegeben.

Ein PrimitivePattern ist ein 'B5'

falls

und	'Abdomen-stark'	∈	[0.315, 1]
und	'Abdomen-reduziert'	∈	[0.368, 0.643]
und	'Thorax-stark'	=	0
und	'Thorax-reduziert'	∈	[0.45, 1]
und	'Thorax/Abdomen-Phase'	∈	[-0.692, -0.111] .

Diesem PrimitivePattern wurde der Name '*reduzierte bis starke gegenläufige Thorax- und Abdomenbewegungen*' gegeben.

Ein PrimitivePattern ist ein 'B6'

falls

und	'Abdomen-stark'	∈	[0.1919, 1]
und	'Thorax-reduziert'	∈	[0, 0.8399]
und	'Thorax-stark'	∈	[0, 1]
und	'Abdomen-kein'	=	0 .

Diesem PrimitivePattern wurde der Name '*starke Thorax- und Abdomenbewegungen*' gegeben.

Ein PrimitivePattern ist ein 'B7'

falls

	'Thorax-stark'	=	0
und	'Abdomen-stark'	=	0
und	'Thorax/Abdomen-Phase'	∈	[-0.735, -0.245] .

Diesem PrimitivePattern wurde der Name '*keine-starken gegenläufige Thorax- und Abdomenbewegungen*' gegeben.

Ein PrimitivePattern ist ein 'B8'

falls

	'Schnarchintensität'	∈	[-0.0405, 0.0545]
und	'Abdomen-reduziert'	∈	[0, 0.3439]
und	'Abdomen-kein'	∈	[0.2079, 1]
und	'Abdomen-stark'	=	0.

Diesem PrimitivePattern wurde der Name '*reduzierte Thoraxbewegungen und keine Abdomenbewegung ohne Schnarchgeräusche*' gegeben.

Ein PrimitivePattern ist ein 'B9'

falls

	'Schnarchintensität'	∈	[0.0185, 0.1645]
und	'Abdomen-stark'	=	0
und	'Thorax-stark'	∈	[0, 0.0997]
und	'Abdomen-reduziert'	∈	[0.1648, 1]
und	'Thorax/Abdomen-Phase'	∈	[-0.675, 0.604] .

Diesem PrimitivePattern wurde der Name '*reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche*' gegeben.

A.7 Fragebogen für Events und Temporal-Patterns

Fragen zu den TemporalPatterns

TemporalPattern1:

gemischt (obstruktive) Apnoe

TWK: [40 sec bis 64 sec] **Experte:** [10 sec bis 3 min]

falls

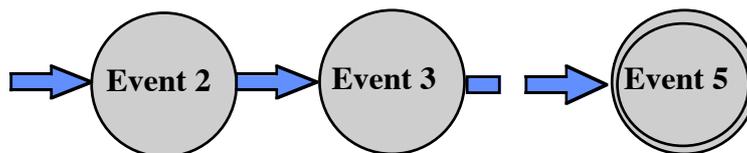
*Event 2: kein Atemvolumen und keinn Thorax und
Abdomenbewegungen ohne Schnarchgeräusche*

gefolgt von

*Event 3: kein Atemvolumen und reduzierte Thoraxbewegungen
und keine Abdomenbewegungen ohne Schnarchgeräusche*

gefolgt nach [0,5 bis 5 sec] von

Event 5: starke Atmung mit Schnarchgeräuschen



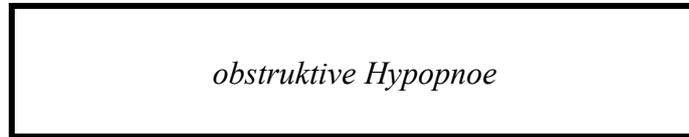
Event2	Name	Dauer
TWK	<i>kein Atemvolumen und keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	[13 sec bis 18 sec]
Experte	<i>zentraler Anteil (einer gemischt obstruktiven Apnoe)</i>	[10 sec bis 3 min]



Event3	Name	Dauer
TWK	<i>kein Atemvolumen und reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche</i>	[20 sec bis 39 sec]
Experte	<i>obstruktiver Anteil (einer gemischt obstruktiven Apnoe)</i>	ok



Event5	Name	Dauer
TWK	<i>starke Atmung mit Schnarchgeräuschen</i>	[6 sec bis 12 sec]
Experte	<i>Hyperpnoe</i>	ok

TemporalPattern2:

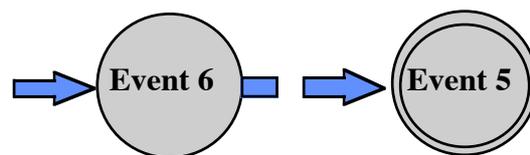
TWK: [19 sec bis 37 sec] **Experte:** [10 sec bis 3 min],

TYP A:**falls**

Event 6: reduziertes Atemvolumen und phasenverschobene Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

gefolgt nach [0 bis 4 sec] von

Event 5 - starke Atmung mit Schnarchgeräuschen.



Event6	Name	Dauer
TWK	<i>reduziertes Atemvolumen und phasenverschobene Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	[20 bis 25 sec]
Experte	<i>Hypopnoe</i>	[10 sec bis 3 min]



Event5	Name	Dauer
TWK	<i>starke Atmung mit Schnarchgeräuschen</i>	[11 bis 15 sec]
Experte	<i>Hyperpnoe</i>	ok

TYP B:**falls**

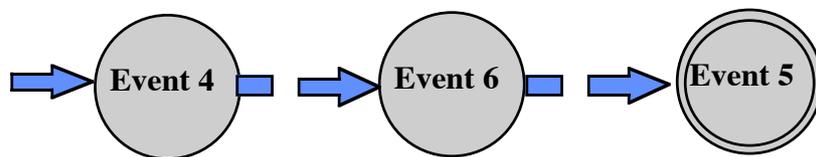
(Event 4 - kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

gefolgt nach [0 bis 8 sec] von

Event 6 - kein bis reduziertes Atemvolumen und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

gefolgt nach [0 bis 5 sec] von

Event 5 - starke Atmung mit Schnarchgeräuschen.



Event4	Name	Dauer
TWK	<i>kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	[2 bis 8 sec]
Experte	<i>keine Bedeutung, in Richtung ausgelassener Atemzug</i>	



Event6	Name	Dauer
TWK	<i>kein bis reduziertes Atemvolumen und phasenverschobene Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	[3 bis 21 sec]
Experte	<i>Hypopnoe</i>	[10 sec bis 3 min]



Event5	Name	Dauer
TWK	<i>starke Atmung mit Schnarchgeräuschen</i>	[11 bis 16 sec]
Experte	<i>Hyperpnoe</i>	ok

TemporalPattern3:

gemischte obstruktive Apnoe

Bemerkung: Es existiert hier noch keine Bezeichnung in der Medizin.

TWK: [18 bis 30 sec]

Experte: [10 sec bis 3 min],

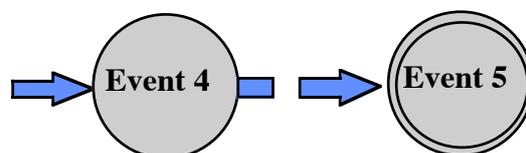
TYP A:

falls

Event 4 - kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

gefolgt nach [1 bis 20 sec] **von**

Event 5 - starke Atmung mit Schnarchgeräuschen.



Event4	Name	Dauer
TWK	<i>kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	[2 bis 27 sec]
Experte	<i>obstruktive Apnoe</i>	[10 sec bis 3 min]



Event5	Name	Dauer
TWK	<i>starke Atmung mit Schnarchgeräuschen</i>	[3 bis 9 sec]
Experte	<i>Hyperpnoe</i>	3 sec zu kurz

TYP B:**falls**

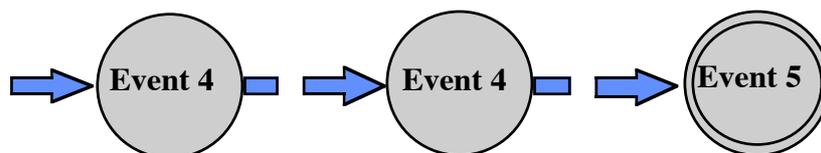
(Event 4 - kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

gefolgt nach [0 bis 8 sec] von

Event 4 - kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche)

gefolgt nach [1 bis 20 sec] von

Event 5 - starke Atmung mit Schnarchgeräuschen.



Event4	Name	Dauer
TWK	<i>kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	[3 bis 6 sec]
Experte	<i>obstruktive Apnoe</i>	



Event4	Name	Dauer
TWK	<i>kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche</i>	[10 bis 22 sec]
Experte	<i>obstruktive Apnoe</i>	



Event5	Name	Dauer
TWK	<i>starke Atmung mit Schnarchgeräuschen</i>	[3 bis 9 sec]
Experte	<i>Hyperpnoe</i>	3 sec zu kurz

TemporalPattern4:



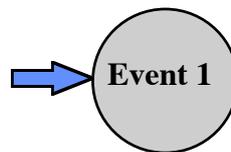
TWK: 6 min

Experte:

falls:

Event1 - reduzierte Atmung mit Schnarchgeräuschen

Bemerkung: Zur Erkennung der Dauer fehlt die Sauerstoffsättigung.



Fragen zu den Events

Event 1: *reduzierte Atmung mit Schnarchgeräuschen,*

obstruktives Schnarchen

falls

(reduziertes Atemvolumen mit Schnarchgeräuschen

oder

Tacet)

ist ungefähr gleichzeitig mit

*reduzierte parallele Thorax- und Abdomenbewegungen mit
Schnarchgeräuschen.*

Atemfluß	Thorax- und Abdomenbewegungen	Häufigkeit	trifft zu	trifft vielleicht zu	trifft nicht zu	weiß nicht
<i>reduziertes Atemvolumen mit Schnarchgeräuschen (1)</i>	<i>reduzierte parallele Thorax- und Abdomenbewegungen (1)</i>	1	X			
<i>Tacet (0)</i>	<i>reduzierte parallele Thorax- und Abdomenbewegungen mit Schnarchgeräuschen (1)</i>	0,1				X

Event2: *kein Atemvolumen und keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche,*

zentraler Anteil (einer gemischten obstruktiven Apnoe)

falls

kein Atemvolumen ohne Schnarchgeräusche

ist ungefähr gleichzeitig mit

(keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche

oder

Tacet) .

Atemfluß	Thorax- und Abdomenbewegungen	Häufigkeit	trifft zu	trifft vielleicht zu	trifft nicht zu	weiß nicht
<i>kein Atemvolumen ohne Schnarchgeräusche(5)</i>	<i>keine Thorax- und Abdomenbewegungen ohne Schnarchgeräusche (3)</i>	0,97	X			
<i>kein Atemvolumen ohne Schnarchgeräusche (5)</i>	<i>Tacet (0)</i>	0,07				X

Event 3: *kein Atemvolumen und reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche,*

obstruktiver Anteil (einer gemischten obstruktiven Apnoe)

falls

kein Atemvolumen ohne Schnarchgeräusche

ist ungefähr gleichzeitig mit

reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche .

Atemfluß	Thorax- und Abdomenbewegungen	Häufigkeit	trifft zu	trifft vielleicht zu	trifft nicht zu	weiß nicht
<i>kein Atemvolumen ohne Schnarchgeräusche(5)</i>	<i>reduzierte Thoraxbewegungen und keine Abdomenbewegungen ohne Schnarchgeräusche (8)</i>	1	X*)			

*) Bezeichnung keine Abdomenbewegungen ist widersprüchlich mit reduzierten Thoraxbewegungen

Event 4: *kein bis reduziertes Atemvolumen und reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen ohne Schnarchgeräusche,*

obstruktive Apnoe

falls

(

(geringes Atemvolumen ohne Schnarchgeräusche

oder

Tacet

oder

reduziertes Atemvolumen ohne Schnarchgeräusche

oder

kein Atemvolumen ohne Schnarchgeräusche)

ist ungefähr gleichzeitig mit

reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen

)

oder

(

geringes Atemvolumen ohne Schnarchgeräusche

ist ungefähr gleichzeitig mit

Tacet

).

Atemfluß	Thorax- und Abdomenbewegungen	Häufig keit	trifft zu	trifft viel- leicht zu	trifft nicht zu	weiß nicht
<i>geringes Atemvolumen ohne Schnarchgeräusche(6)</i>	<i>reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen (9)</i>	0,96	X			
<i>Tacet(0)</i>	<i>reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen (9)</i>	0,76				X
<i>reduziertes Atemvolumen ohne Schnarchgeräusche (8)</i>	<i>reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen (9)</i>	0,29		X		
<i>kein Atemvolumen ohne Schnarchgeräusche (5)</i>	<i>reduzierte parallele und gegenläufige Thorax- und Abdomenbewegungen (9)</i>	0,07	X			

Atemfluß	Thorax- und Abdomenbewegungen	Häufig keit	trifft zu	trifft viel- leicht zu	trifft nicht zu	weiß nicht
<i>geringes Atemvolumen ohne Schnarchgeräusche (6)</i>	<i>Tacet (0)</i>	0,06	X			

Event 5: *großes Atemvolumen und starke Thorax- und Abdomenbewegungen,*

Hyperpnoe

falls

(großes Atemvolumen mit Schnarchgeräuschen

oder

Tacet

oder

reduziertes Atemvolumen mit Schnarchgeräuschen)

ist ungefähr gleichzeitig mit

starke Thorax- und Abdomenbewegungen .

Atemfluß	Thorax- und Abdomenbewegungen	Häufigkeit	trifft zu	trifft vielleicht zu	trifft nicht zu	weiß nicht
<i>großes Atemvolumen (7)</i>	<i>starke Thorax- und Abdomenbewegungen (6)</i>	1	X			
<i>Tacet (0)</i>	<i>starke Thorax- und Abdomenbewegungen (6)</i>	0,41				X
<i>reduziertes Atemvolumen mit Schnarchgeräusche (9)</i>	<i>starke Thorax- und Abdomenbewegungen (6)</i>	0,14				X

Event 6: *reduziertes Atemvolumen und gegenläufige Thorax- und Abdomen-bewegungen ohne Schnarchgeräusche,*

<i>Hypopnoe</i>

falls

(
 (*geringes Atemvolumen ohne Schnarchgeräusche*
 oder
 reduziertes Atemvolumen ohne Schnarchgeräusche)

ist ungefähr gleichzeitig mit
gegenläufige Thorax- und Abdomenbewegungen

)
oder

(
 reduziertes Atemvolumen ohne Schnarchgeräusche
ist ungefähr gleichzeitig mit
 Tacet

).)

Atemfluß	Thorax- und Abdomenbewegungen	Häufigkeit	trifft zu	trifft vielleicht zu	trifft nicht zu	weiß nicht
<i>geringes Atemvolumen ohne Schnarchgeräusche (9)</i>	<i>gegenläufige Thorax- und Abdomenbewegungen (4)</i>	1	X			
<i>reduziertes Atemvolumen ohne Schnarchgeräusche (8)</i>	<i>gegenläufige Thorax- und Abdomenbewegungen (4)</i>	0,26	X			

Atemfluß	Thorax- und Abdomenbewegungen	Häufigkeit	trifft zu	trifft vielleicht zu	trifft nicht zu	weiß nicht
<i>reduziertes Atemvolumen ohne Schnarchgeräusche (8)</i>	<i>Tacet (0)</i>	0,41				X

Glossar

Abdomenbewegungen

siehe kardiorespiratorische Polysomnographie (PSG).

Ableitung

Ersetzung der linken Seite einer Ableitungsregel durch die rechte Seite.

Ableitungsregel

Regel aus einer Grammatik.

Abstraktionsebenen

Ebenen, die durch die Methode zur temporalen Wissenskonversion (TWK) eingeführt werden (s. Kapitel 3.2).

Atemfluß

siehe kardiorespiratorische Polysomnographie (PSG).

Bestmatch

Das dem Eingabevektor auf der Merkmalskarte gemäß einer gegebenen Metrik ähnlichste Neuron.

Clusteranalyse

Verfahren aus der explorativen Statistik zur Erkennung von Strukturen in einer Menge von Objekten.

Distanz-Methode

siehe U-Matrix-Methode.

Eingabeschicht

Schicht zur Aufnahme eines mehrdimensionalen Eingabevektors.

Endevent

Event mit dem eine Sequence endet.

Event

Ungefähr gleichzeitig auftretende Successions (s. Definition 3.1.7).

Eventfolge

Aufeinanderfolgende Events und EventTacets.

EventKlasse

Events, die aus denselben ungefähr gleichzeitig auftretenden Successions bestehen, und die einer Klasse zugeordnet werden können (s. Definition 3.1.7).

EventTacet

Ungefähr gleichzeitig auftretende Tacets.

Formale Sprache

Menge von Worten, die formal durch eine Grammatik beschreibbar ist, wobei die Zugehörigkeit der Worte zur Sprache anhand der syntaktischen Regeln der Grammatik bestimmt wird.

Fuzzy-Theorie

Theorie unscharfer Mengen.

Gewicht

Gewichtete Kante zwischen Neuronen in einem künstlichen neuronalen Netz, die während des Lernens ggf. verändert wird.

gleitende temporale Wissenskonzersion

siehe Wissenskonzersion.

Grammatik

Regelsystem zur Erkennung bzw. Generierung von Wörtern einer Sprache.

high-level Mustererkennung

siehe Mustererkennung.

HS

siehe hybride Systeme.

HSW

siehe hybride Systeme mit Wissenskonzersion.

hybrid

Zwitterbildung, Mischbildung oder Zusammensetzung aus Verschiedenem.

hybride Systeme (HS)

Systeme, bei denen die verschiedenen Module durch unterschiedliche Technologien realisiert werden.

kooperierende hybride Systeme (KHS)

Hybride Systeme, bei denen eine Art Kooperation bzw. Interaktion zwischen den einzelnen Komponenten realisiert ist.

hybride Systeme mit Wissenskonzersion (HSW)

Hybride Systeme, bei denen ein Übergang zwischen subsymbolischer und symbolischer Wissenskonzersion stattfindet.

hybride Systeme mit Wissenskonzersion

siehe hybride Systeme.

kardiorespiratorische Polysomographie (PSG)

Registrierung von schlafbezogenen Signalen (EEG, EOG, EMG), atmungsbezogenen Signalen (Atemfluß, Thorax- und Abdomenbewegungen, Sauerstoffsättigung, Schnarchgeräusche) und kardiovaskuläre Signale (EKG, Blutdruck).

KI

siehe Künstliche Intelligenz.

KHS

siehe kooperierende hybride Systeme.

Klasse

Ähnliche Objekte, die in eine Gruppe von Objekten fallen.

KNN

siehe Künstliche Neuronale Netze.

komplexes Muster

siehe Muster.

Komponente

Komponente eines mehrdimensionalen Vektors.

Komponenten-Karten

Graphische Darstellung einer Komponente auf einer selbstorganisierenden Merkmalskarte (SOM).

komplexe Muster in multivariaten Zeitreihen

Muster in multivariaten Zeitreihen, die aus primitiven Mustern und / oder auch komplexeren Muster auf verschiedenen hierarchischen Abstraktionsebenen zusammengesetzt sind und die zeitliche und hierarchische Anhängigkeiten untereinander aufweisen.

kooperierende hybride Systeme (KHS)

siehe hybride Systeme

kontextfreie Grammatik

Spezieller Grammatiktyp, der häufig in der Informatik eingesetzt wird.

kontextfreie Sprachen

Durch kontextfreie Grammatiken erzeugte Sprachen.

künstliche Intelligenz (KI)

Fachgebiet aus der Informatik

künstliche neuronale Netze (KNN)

Vernetzte, d.h. durch gewichtete Verbindungen gekoppelte, künstliche Neuronen, die sich durch Veränderungen der Gewichte (Lernen) an die Lerndaten anpassen.

Lerndaten

Daten, die zum Anlernen eines künstlichen neuronalen Netzes verwendet werden.

Lernen

Veränderung der Gewichte durch Anpassung an Lerndaten.

Lernrate

Faktor, der bei der Veränderung der Gewichte multipliziert wird.

Lernschritt

Veränderung der Gewichte zu einem Zeitpunkt.

Lernverfahren

Verfahren, mit dem ein künstliches neuronales Netz angelehrt wird.

unüberwachtes

Strukturelle Eigenschaften der Lerndaten werden zur Veränderung der Gewichte verwendet.

überwachtes

Qualität des Netzes wird an einer Zielfunktion gemessen.

Merkmal

Ergebnis einer Transformation von Zeitreihen in eine neue Repräsentationsform (s. Definition 3.1.2).

Merkmalsextraktion

Gewinnung von Merkmalen.

Merkmalsfolge

Die zu allen möglichen Zeitpunkten berechneten Merkmale aus einer Selektion von Zeitreihen.

MESAM

Registrierung von Herzfrequenz, Sauerstoffsättigung und Schnarchgeräuschen.

Methode zur temporalen Wissenskonzersion (TWK)

Methode zur Entdeckung von komplexen Mustern in multivariaten Zeitreihen und deren Überführung in eine symbolische Wissensrepräsentation (s. Kapitel 3).

multivariate Merkmalsfolge

Mehrere aus verschiedenen Selektionen von Zeitreihen berechnete Merkmalsfolgen.

multivariate PrimitivePattern-Folge

Mehrere aus verschiedenen Selektionen von Zeitreihen berechnete PrimitivePattern-Folgen.

multivariate Zeitreihe

Mehrere zu endlich vielen äquidistanten Zeitpunkten abgetastete zeitabhängige Größen (s. Definition 3.1.1).

Muster

Regelmäßiges, sich wiederholendes Auftreten von Signalen, Bildern, etc. oder deren Bestandteile.

komplexes Muster

Zusammengesetzt aus mehreren primitiven Mustern, die eine bestimmte strukturelle bzw. hierarchische Beziehung untereinander aufweisen.

primitives Muster

Wird durch Merkmale beschrieben, die eine Zuordnung des primitiven Musters als Ganzes in eine Klasse erlauben.

Mustererkennung

Verfahren zur Klassifikation von primitiven Mustern und Analyse, Beschreibung und Interpretation von komplexen Mustern.

low-level

Vorverarbeitung und Segmentierung von komplexen Mustern auf einer datennahen Ebene.

high-level

Erkennung und Beschreibung von strukturellen bzw. hierarchischen Abhängigkeiten zwischen primitiven Mustern.

statistische

Einsatz von statistischen Methoden zur Mustererkennung.

syntaktische

Einsatz von Methoden aus der theoretischen Informatik zur Mustererkennung.

Mustererkennungssystem

Komplexes, meist aus mehreren Verfahren zusammengesetztes System zur Erkennung von komplexen Mustern.

Nachbarschaft

Neuronen in einer Umgebung um einen Bestmatch, die bei dem Lernen berücksichtigt werden.

Neuronen

Verarbeitungseinheiten (Units) in einem künstlichen neuronalen Netz.

Neuronenschicht

Anordnung von Neuronen in einer Schicht.

Nichtterminale

Endliche Menge von Hilfszeichen einer Grammatik.

Parser

Computerprogramm, gesteuert durch eine Grammatik, das für ein Wort überprüft, ob dieses durch die Grammatik erzeugt werden kann.

PrimitivePattern

Zu einem bestimmten Zeitpunkt auftretende Element einer Primitive-Pattern-Klasse (s. Definition 3.1.3).

PrimitivePattern-Folge

Durch eine Strukturanalyse von Selektionen von Merkmalen bestimmte PrimitivePatterns.

primitives Muster

siehe Muster.

Prolog

Logische Programmiersprache.

PSG

siehe kardiorespiratorische Polysomnographie

Sauerstoffsättigung

siehe kardiorespiratorische Polysomnographie (PSG).

Schlafapnoen

siehe schlafbezogene Atmungsstörungen.

schlafbezogene Atmungsstörungen (SBAS)

Krankheit, die Schlafstörungen hervorruft, wobei Veränderungen in autonomen Funktionen des menschlichen Körpers auftreten (s. Kapitel 5.1).

Schnarchgeräusche

siehe kardiorespiratorische Polysomnographie (PSG).

selbstorganisierende Merkmalskarte (SOM)

Künstliches neuronales Netz mit unüberwachtem Lernverfahren, das sich durch Selbstorganisation an die strukturellen Eigenschaften von hochdimensionalen Daten anpassen kann und daher zur Erkennung von Strukturen in hochdimensionalen Daten eingesetzt werden kann.

Selektion von Merkmalen

Ausgewählte Merkmale einer multivariaten Merkmalsfolge.

Semantik

Bedeutung von Wörtern einer Sprache.

Sequence

Teilfolge von Events, die sich in einer Eventfolge wiederholen (s. Definition 3.1.8).

sig*

Regelgenerierungsalgorithmus, dessen Regeln anhand von Signifikanztabellen erzeugt werden.

sig*-Regeln

Regeln, die durch den Regelgenerierungsalgorithmus sig* erzeugt werden.

SOM

siehe selbstorganisierende Merkmalskarten.

Sprache

Enthält ein Vokabular und einen Satz von grammtikalischen Regeln.

Sprachkonstrukt

spezielle Terminalsymbole (Terminale).

Startevent

Event mit dem eine Sequence startet.

statistische Mustererkennung

siehe Mustererkennung.

Strukturanalyse

Erzeugung einer computergraphischen Darstellung von hochdimensionalen Daten zur Erkennung von Strukturen in hochdimensionalen Daten und deren Beschreibung in einer sprachlichen Form (s. Kapitel 2.1.2).

Succession

Unmittelbar aufeinanderfolgende gleiche PrimitivePatterns (s. Definition 3.1.4).

Symbol

Ein atomares, nicht zerlegbares Gebilde zur Darstellung eines Begriffsinhaltes oder Sachverhaltes.

Syntax

Syntaktischer Aufbau von Wörtern einer Sprache.

syntaktische Mustererkennung

siehe Mustererkennung.

Syntaxanalyse

Überprüfung der syntaktischen Korrektheit von Wörtern einer Sprache.

Tacet

Spezielle Klasse, die auf keinem Fall eine PrimitivePattern-Klasse ist.

temporale Grammatik

Unifikationsbasierte Grammatik, durch die komplexe Muster in multivariaten Zeitreihen sprachlich beschrieben werden, und die aus den Zwischenergebnissen der TWK erzeugt wird (s. Kapitel 3.4).

temporale, symbolische Wissensrepräsentation

siehe Wissensrepräsentation.

temporale, subsymbolische Wissensrepräsentation

siehe Wissensrepräsentation.

temporale Wissenskonversion

siehe Wissenskonversion.

TemporalPattern

Alternativen zwischen ähnlichen Sequences (s.).

TG

siehe temporale Grammatik.

TG-Regeln

Regeln einer temporalen Grammatik (s. Kapitel 3.4).

Thoraxbewegungen

siehe kardiorespiratorische Polysomnographie (PSG).

Terminale

Wörter oder Zeichen aus einem endlichen Alphabet, über dem die zu erzeugende Sprache definiert ist.

„topographische“ Organisationsprinzip

Funktionsprinzip des biologischen Gehirns, bei dem benachbarte Neuronen einer Schicht des Gehirns aus dem Ausgangsfeld mit benachbarten Neuronen aus dem Zielfeld verbunden sind.

Two-Match-Methode

siehe U-Matrix-Methode.

TWK

siehe Methode zur temporalen Wissenskonversion.

überwachtes Lernverfahren

siehe Lernverfahren.

Unifikation

Durch Substitution gesuchte Belegung von Variablen in Termen, so daß Terme gleich gemacht werden können.

Unifikationsbasierte Grammatik

Axiomatisierte kontextfreie Grammatik, deren Ableitungen durch Unifikation in Form einer Beweisstrategie erfolgt.

unüberwachtes Lernverfahren

siehe Lernverfahren.

U-Matrix

Visualisierung der Netzstruktur einer selbstorganisierenden Merkmalskarte (SOM) durch eine dreidimensionale Landschaft.

U-Matrix-Methode

Methode zur Erzeugung einer dreidimensionalen Landschaft aus einer selbstorganisierenden Merkmalskarte.

Distanz-Methode

Abstände zwischen benachbarten Gewichten werden in eine dritte Dimension abgebildet.

Two-Match-Methode

Abstände zwischen benachbarten BestMatches werden gewichtet und in die dritte Dimension abgebildet.

Wissen

ist in Menschen als Wahrnehmungen, Erfahrungen und Kenntnisse vorhanden und kann sprachlich rekonstruiert werden.

wissensbasierte System

Computerprogramm, welches eine Wissensbasis, eine Inferenzkomponente und eine Erklärungskomponente besitzt.

Wissenskonversion

Übergang zwischen subsymbolischer und symbolischer Wissensrepräsentation.

temporale

Übergang zwischen multivariaten Zeitreihen und einer temporalen, symbolischen Wissensrepräsentation für komplexe Muster in den Zeitreihen.

temporale gleitende

Schrittweise Übergang zwischen multivariaten Zeitreihen und einer temporalen, symbolischen Wissensrepräsentation für komplexe Muster in den Zeitreihen, der nicht ad hoc, sondern in mehreren kleinen Schritten erfolgt.

Wissensrepräsentation

Abbildung von Wissen in einen für Menschen und Maschinen verständlichen Formalismus.

symbolische

Mit Hilfe von Zeichen repräsentiertes Wissen in einer für Menschen verständlichen, sprachlichen Form.

subsymbolische

Aufteilung eines zu repräsentierenden Symbols auf eine Vielzahl von Einheiten, die für sich alleine keine Bedeutung besitzen.

temporale, symbolische

Mit Hilfe von Zeichen repräsentiertes zeitliches Wissen in einer für Menschen verständlichen, sprachlichen Form.

temporale, subsymbolische

Repräsentation einer Zeitreihe durch eine Vielzahl von Werten (Einheiten), die für sich alleine keine Bedeutung tragen.

Zeitreihe

Eine zu endlich vielen äquidistanten Zeitpunkten abgetastete zeitabhängige Größe.

zusammengesetzter Term

Besteht aus einem Funktor und Argumenten, die wiederum aus Konstanten, Variablen und zusammengesetzten Termen bestehen können.

Index

A

Abstraktionsebene	48, 79
Ausreißer	74

B

Bestmatch	15, 78
-----------------	--------

C

Clusteranalyse	51, 57
----------------------	--------

E

Eingabeschicht	14
Eingabevektor.....	14, 15
Endevent	45, 52, 61, 108
Ereignisstrukturen	166, 169
Evaluation.....	124, 130
Event.....	42, 51, 59, 60, 61, 65, 69, 77, 79, 82, 101, 105, 117, 118, 127, 132, 134, 143
Eventfolge	44
EventTacet.....	42, 52, 59, 61, 108
Expertenbefragung	124, 130, 131, 134, 143, 145, 146

F

Fragebogen.....	130
Fuzzy	24

G

Gewichte	14
Grammatik	31, 63
kontextfreie	64
unifikationsbasierte (UBG)	64, 65
grammatikalische Inferenz	31
grammatikalische Regeln	43

H

hybrid	24
hybride Systeme	24, 170
kooperierende	25, 170
mit Wissenskonzersion	25, 171, 173

I

Interpreter	21
Intervallstrukturen	163, 164, 165, 169

K

kardiorespiratorische Polysomnographie (PSG)	84, 86, 89
Klasse	29
Klassifikator	29
komplexe Muster	27, 30, 33
komplexe Muster in multivariaten Zeitreihen	26, 70, 143, 161, 168, 170
Komponentenkarten	80, 155
Kreuzkorrelation	92
künstliche Intelligenz (KI)	24
künstliche neuronale Netze (KNN)	24, 25, 75

L

laterale Inhibition	14
Lerndaten	14
Lernen	15
Lernprozeß	16
Lernradius	16
Lernrate	16
Lernschritt	14

Lernverfahren	
überwachte	14
unüberwachte.....	14, 51, 57

M

Merkmal.....	36, 38, 50
Merkmalsextraktion	29, 35, 50, 55, 56, 75, 89
Merkmalsfolge	36
Mustererkennung.....	27, 28
high-level.....	28
low-level	28, 30
statistische	28
syntaktische.....	30, 167
Mustererkennungssystem	29

N

Nachbarschaft.....	14
Neuronen	14
Neuronenschicht	14
Normalverteilung.....	74

P

Parser	64, 65
primitive Muster	27, 30, 31, 37
PrimitivePattern	38, 50, 56, 76, 94, 101, 125, 133
PrimitivePattern-Folge	38, 76
multivariate	76
PrimitivePattern-Klasse	38, 50, 56, 59, 76, 81, 95
Punktstrukturen	163

R

Regel.....	63, 65
------------	--------

S

schlafbezogene Atmungsstörungen (SBAS)	
.....	34, 40, 46, 84, 86, 93, 118, 120, 122, 125, 134, 162, 169
selbstorganisierende Merkmalskarte (SOM).....	13, 16, 51, 55, 57, 75, 76, 78, 94, 150
hierarchische	52, 60, 77, 159, 162
semantische Maschine.....	21
Sequence	45, 52, 61, 65, 68, 82, 106, 117, 120, 127, 131, 139
sig*	39, 51, 95, 103, 117, 125, 162
Sprache.....	63
Spracherkennung	29
Startevent.....	45, 52, 61, 108
String	53, 61, 62, 111
Strukturanalyse.....	36, 37, 38, 50, 56, 57, 74, 76, 94, 95, 162
Succession	40, 51, 58, 99, 126
Successions	
ungefähr gleichzeitig auftretende	41, 59, 76, 103
Symbol	21, 42, 44
Syntaxanalyse.....	64, 65

T

Tacet.....	38, 40, 51, 58, 76, 95
temporale Grammatik (TG)	65, 117, 170
temporale Wissenskonversion.....	26, 33, 37, 42, 48, 51, 52, 58, 60, 76
TemporalPattern	
.....	47, 48, 53, 62, 65, 67, 82, 90, 111, 117, 122, 124, 127, 130, 131, 139, 143, 146
TG-Regel	43, 45, 47, 52, 53, 67, 68, 69, 79, 105, 118, 124, 127, 128, 131, 143
topographische Organisationsprinzip	13
TWK	48, 49, 54, 70, 71, 105, 124, 125, 143

U

U-Matrix	20, 39, 51, 52, 76, 80, 94, 156, 162
U-Matrix-Methode	38, 57
Unifikation	65

V

Vorverarbeitung.....	74
----------------------	----

W

Wege	58, 79, 81, 150, 153
Wissen	22, 124, 132, 143, 144, 147
Wissensakquisition.....	172
Wissenskonversion.....	25
Wissensrepräsentation.....	21, 22
subsymbolische	22, 25
symbolische.....	23, 25, 33, 43, 45, 70

Z

Zeitreihen.....	25
multivariate	33, 34, 35, 48
Zugehörigkeitsfunktion.....	91
zusammengesetzte Terme.....	64

Abbildungsverzeichnis

Abb.1	: Selbstorganisierende Merkmalskarte (SOM).....	15
Abb.2	: Verschiedene Distanzfunktionen für eine Merkmalskarte: . a) gaußsche Glockenkurve, b) Zylinder, c) Konus, d) Kosinus (in [Zell 94]).	17
Abb.3	: Einfachste U-Matrix-Methode, die Distanz-Methode (in [Ultsch 92]).	19
Abb.4	: U-Matrix der Oktaeder-Daten.....	20
Abb.5	: Noten aus Georges Bizet's Oper Carmen	23
Abb.6	: Schritte bei der Entwicklung eines Mustererkennungssystems in der Statistik (in [Kanal/Dattatreya 92]).	29
Abb.7	: Grundbausteine eines syntaktischen Mustererkennungssystems (in [Kanal/Dattatreya 92])......	31
Abb.8	: Multivariate Zeitreihe am Beispiel eines Patienten mit schlafbezogenen Atmungsstörungen	35
Abb.9	: Multivariate Zeitreihe und multivariate Merkmalsfolge am Beispiel eines Patienten mit schlafbezogenen Atmungsstörungen	37
Abb.10	: Multivariate Zeitreihe und multivariate PrimitivePattern-Folge am Beispiel eines Patienten mit schlafbezogenen Atmungstörungen.	39
Abb.11	: Beispiel für zwei ungefähr gleichzeitig auftretende Successions.....	41

Abb.12 : Multivariate Zeitreihe, Events und EventFacets am Beispiel eines Patienten mit schlafbezogenen Atmungsstörungen	43
Abb.13 : Schritte der Methode zur temporalen Wissenskonversion (TWK)....	49
Abb.14 : Methode zur temporalen Wissenskonversion (TWK) im Überblick.	66
Abb.15 : Hierarchische SOM mit U-Matrizen.....	77
Abb.16 : Kodierung der Eingabevektoren	78
Abb.17 : Weg auf einer U-Matrix mit mehreren Successions.....	81
Abb.18 : U-Matrix mit Übergangshäufigkeiten.....	82
Abb.19 : Ein Registrierbeispiel mit allen Kurven einer kardiorespiratorischen Polysomnographie (PSG) [in Penzel (1995)]	85
Abb.20 : Schlafbezogene Atmungsstörungen (SBAS) unterteilt in amplitudenabhängige und in phasenabhängige Störungen [in Penzel (1995)]	86
Abb.21 : Fuzzy-Membership-Funktionen für Atemvolumen.....	91
Abb.22 : Fuzzy-Membership-Funktionen für Thoraxbewegungen	92
Abb.23 : Fuzzy-Membership-Funktionen für Abdomenbewegungen.....	92
Abb.24 : Histogramme für Kreuzkorrelationen aus Daten mit (a) gegenläufigen (uncorr) und (b) parallelen (corr) Thorax- und Abdomenbewegungen	93
Abb.25 : AirflowUMX, 64x64 Matrix, 400 tausend Lernschritte, toroid angelernt.....	97
Abb.26 : PrimitivePattern-Klassen der AirflowUMX	97
Abb.27 : ThoraxAbdomenUMX, 64x64 Matrix, 400 tausend Lernschritte, toroid angelernt.	98
Abb.28 : PrimitivePattern-Klassen der ThoraxAbdomenUMX	98

Abb.29 : Eliminierung von sehr kurzen Unterbrechungen in Successions.....	100
Abb.30 : Histogramm für die empirischen bedingten Wahrscheinlichkeiten P (Ai Bj) und P (Bj Ai) der gleichzeitig auftretenden PrimitivePatterns aus AirflowUMX und ThoraxAbdomenUMX.....	102
Abb.31 : Histogramm für die relativen Übergangs-häufigkeiten zwischen Events (mit und ohne EventTacet).....	107
Abb.32 : Automat mit Events und Übergängen zwischen Events.....	108
Abb.33 : Histogramm für die Dauer aller EventTacets	109
Abb.34 : Prozentuale Anzahl von Events vor bzw. nach einem länger andauernden EventTacet	109
Abb.35 : TemporalPattern1 mit den Events und den Zeitreihen Atemfluß, Tho- rax- und Abdomenbewegungen und Schnarchintensität.....	113
Abb.36 : TemporalPattern2 mit den Events und den Zeitreihen Atemfluß, Tho- rax- und Abdomenbewegungen und Schnarchintensität.....	114
Abb.37 : TemporalPattern3 mit den Events und den Zeitreihen Atemfluß, Tho- rax- und Abdomenbewegungen und Schnarchintensität.....	115
Abb.38 : TemporalPattern4 mit den Events und den Zeitreihen Atemfluß, Tho- rax- und Abdomenbewegungen und Schnarchintensität.	116
Abb.39 : Beispiel für eine graphische Darstellung der Sequences von TemporalPattern3	127
Abb.40 : Beispiel für eine graphische Darstellung der Events und EventTacets ei- nes TemporalPatterns zusammen mit der multivariaten Zeitreihe... ..	129
Abb.41 : Vorgehensweise bei der Expertenbefragung	131
Abb.42 : Aufbau eines Fragebogens zur Verifizierung der TG-Regeln der Tem- poralPatterns	132
Abb.43 : Aufbau eines Fragebogens zur Verifizierung der TG-Regeln der Events	133

Abb.44 : Ergebnisse der Expertenbefragung für alle Events.....	144
Abb.45 : Ergebnisse der Expertenbefragung für die ungefähr gleichzeitig auftretenden Successions in den TG-Regeln der Events	145
Abb.46 : Merkmalskarte mit 21 finnischen Phonemen (in [Kohonen 88]). ...	151
Abb.47 : Weg auf einer SOM für das finnische Wort "humppila" (in [Kohonen 88]).	151
Abb.48 : Wege auf SOM zur Identifikation von normaler, akzeptabler und unakzeptabler Aussprache von "s"-Lauten von 11 Frauen im Alter von 16-18 Jahren (in [Mujunen et al. 93])	152
Abb.49 : Wege von zwei verschiedenen Ausschnitten eines EEG's (in [Joutsieniemi et al. 95]).	153
Abb.50 : Chemische Destillationskolonne und Weg auf einer Komponentenkarte für die Temperatur (in [Tryba/Goser 91]).	155
Abb.51 : U-Matrix zur Überwachung und Steuerung von chemischen Prozessen (in [Ultsch 93]).	156
Abb.52 : Semantische Merkmalskarte für Namen von Tieren (in [Ritter/Kohonen 89]).	157
Abb.53 : Erweiterte SOM zur Robotersteuerung (in [Ritter et al. 92]).	158
Abb.54 : Hierarchische SOM zur Erkennung von Proteinsequenzen (in [Andrade et al. 97]).	160
Abb.55 : Relationen zwischen Intervallen für Allen's (1984) eingeführte Intervallstrukturen (in [Vila 94]).	164
Abb.56 : Intervallstrukturen zur Darstellung von Mustern in Zeitreihen (in [Haimowitz/Kohane 96]).	165
Abb.57 : Intervallstrukturen zur Diagnose unterschiedlicher Hepatitis Krankheiten (in [Gamper/Nejdl 97]).	166
Abb.58 : Ereignisse auf verschiedenen Ebenen (in [Chittaro/Dojat 97]).	167

Tabellenverzeichnis

Tabelle 1 : Dauer von sehr kurzen Successions aus AirflowUMX	99
Tabelle 2 : Dauer von sehr kurzen Successions aus ThoraxAbdomenUMX..	100
Tabelle 3 : Empirische bedingte Wahrscheinlichkeiten $P(A_i B_j)$ für die PrimitivePatterns aus AirflowUMX.....	101
Tabelle 4 : Empirische bedingte Wahrscheinlichkeiten $P(B_j A_i)$ für die PrimitivePatterns aus ThoraxAbdomenUMX	102
Tabelle 5 : Sehr häufige Events	103
Tabelle 6 : Weniger Häufige Events.....	104
Tabelle 7 : Dauer von sehr kurzen Events	105
Tabelle 8 : Relative Übergangshäufigkeiten zwischen Events.....	106
Tabelle 9 : Ähnlichkeitstabelle für Sequences.....	112
Tabelle 10 : Absolute Häufigkeit von gleichzeitig auftretenden PrimitivePatterns aus AirflowUMX (A_i) und ThoraxAbdomenUMX (B_j).....	191
Tabelle 11 : Übereinstimmung der Merkmale in den sig*-Regeln (in Prozente) für die Events ohne Tacet.	191

Literaturverzeichnis

- [Abramson/Dahl 89] Abramson, H., Dahl, V.: Logic Grammars, Springer, New York, 1989.
- [Aho 90] Aho, A.V.: Algorithms for Finding Patterns in Strings. In: J.V. Leeuwen (ed.): Algorithms and Complexity: Handbook of Theoretical Computer Science, Vol. A, Elsevier Science Publisher, Amsterdam, 1990.
- [Aho et al. 86] Aho, A.V., Sethi, R., Ullman, J.D.: Compilers, Principles, Techniques, Tools. Addison-Wesley, 1986.
- [Ajjanagadde/Shastri 95] Ajjanagadde, V., Shastri, L.: Integrating Symbol Processing Systems and Connectionist Networks. In: S. Goonatilake, S. Khebal (Eds.): Intelligent Hybrid Systems, Wiley&Sons, New York, 1995, S.209-220.
- [Alander et.al. 91] Alander, J.T., Frisk, M., Holmström, L., Hämäläinen, A., Tuominen, J.: Process Error Detection using Self-Organizing Feature Maps. In: T. Kohonen, K. Mäkisara, O. Simula, J. Kangas (Eds.): Artificial Neural Networks, Elsevier Science Publisher, North Holland, 1991, S. 1229-1233.
- [Aliferis et al. 97] Aliferis, C.F., Cooper, G.F., Pollack, M.E., Buchanan, B.G., Wagner, M.M.: Representing and developing temporally abstracted knowledge as a means towards facilitating time modeling in medical decision-support systems. In: Computers in Biology and Medicine, Vol. 27, No. 5, Elsevier Science Publisher, 1997, S. 411-434.
- [Allen 84] Allen, J.: Towards a General Theory of Action and Time. Artificial Intelligence 23, 1984, S. 123-154.

- [America 94] Sleep Apnea, Sleepiness, and Driving Risk. American Thoracic Society, Medical Section of the American Lung Association. In: American Journal of Respiratory and Critical Care Medicine, Vol. 150, 1994, S. 1463-1473.
- [Anders 93] Anders, U.: Multivariate Zeitreihenanalyse mit Neuronalen Netzwerken. Diplomarbeit, Institut für Statistik und mathem. Wirtschaftstheorie, Universität Karlsruhe, 1993.
- [Anderson 94] Anderson, T.R.: Auditory Models with Kohonen SOFM and LVQ for Speaker Independent Phoneme Recognition. Proc. Intl. Conf. on Neural Networks, Vol. 1, Piscataway, NJ, IEEE Service Center, 1994, S. 4466 - 4469.
- [Andrade et al. 97] Andrade, M.A., Casari, G., Sander, C., Valencia, A.: Classification of protein families and detection of the determinant residues with an improved self-organizing map. In: Biological Cybernetics 76, 1997, S. 44-450.
- [Andrews et al. 95] Andrews, R., Diederich, J., Tickle, A.B.: Survey and critique of techniques for extracting rules from trained artificial neural networks. In: Knowledge-Based Systems, Volume 8, Number 6, December, Elsevier Science Publisher, 1995, S.373-389.
- [Beach/Gevarter 91] Beach, S.S., Gevarter, W.: Standards for Evaluating Expert Systems Tools. In: Expert Systems with Applications, Vol. 2, 1991, S. 259 - 267.
- [Behme et al. 93] Behme, H., Brandt, W.D., Strube, H.W.: Speech Recognition by Hierarchical Segment Classification. In: S. Gielen, B. Kappen (Eds.): Proc. Intl. Conf. on Artificial Neural Networks (ICANN 93), Amsterdam, Springer Verlag, London, 1993, S. 416-419.
- [Bezdek 95] Bezdek, J.C.: Hybrid modeling in pattern recognition and control. In: Knowledge-Based Systems, Vol. 8, Number 6, Elsevier Science Publisher, 1995, S.359-371.
- [Bibel et al. 93] Bibel, W., Hölldobler, S., Schaub, T.: Wissensrepräsentation und Inferenz. Springer Verlag, Braunschweig, 1993.
- [Bishop 95] Bishop, C.M.: Neural Networks for Pattern Recognition. Oxford, Clarendon Press, 1995.

- [Blazadonakis et al. 96] Blazadonakis, M., Moustakis, V., Charissis, G.: Deep assessment of machine learning techniques using patient treatment in acute abdominal pain in children. In: *Artificial Intelligence in Medicine* 8, Elsevier Science Publisher, 1996, S. 527-542.
- [Bock 74] Bock, H.H.: *Automatische Klassifikation, Theoretische und praktische Methoden zur Gruppierung und Strukturierung von Daten*. Vandenhoeck&Ruprecht Verlag, Göttingen, 1974
- [Bolc 87] Bolc, L.: *Natural Language Parsing Systems*. Springer Verlag, Berlin, 1987.
- [Brückner et.al. 92] Brückner, B., Franz, M., Richter, A.: A Modified Hypermap Architecture for Classification of Biological Signals. In: I. Aleksander, J. Taylor (Eds.): *Artificial Neural Networks*, 2, Elsevier Science Publisher, 1992, S. 1167-1170.
- [Bürsner et al. 95] Bürsner, S., Spreckelsen, C., Nebe, J., Spitzer, K.: Epistemologische Adäquatheit bei der Akquisition und formalen Repräsentation neurologischen Wissens. In: *Informatik, Biometrie und Epidemiologie in Medizin und Biologie* 26 (39), Eugen Ulmer Verlag, Stuttgart, 1995, S. 229-239.
- [Bukharaev 95] Bukharaev, R.G.: *Theorie der stochastischen Automaten*. Teubner Verlag, Stuttgart, 1995.
- [Bruha/Kockova 93] Bruha, I, Kockova, S.: Quality of Decision Rules: Empirical and Statistical Approaches. *Informatica* 17, 1993, S. 233-243.
- [Chappel/Taylor 93] Chappel, G.J., Taylor, J.G.: The Temporal Kohonen Map. *Neural Networks*, Vol. 6, 1993, S. 441-445.
- [Chittaro/Dojat 97] Chittaro, L., Dojat, M.: Using a general theory of time and change in patient monitoring: experiment and evaluation. In: *Computers in Biology and Medicine*, Vol. 27, No.5, Elsevier Science Publisher, 1997, S. 435-452.
- [Cimino/Barnett 93] Cimino, J.J., Barnett, G.O.: Automatic Knowledge Acquisition from MEDLINE. In: *Methods of Information in Medicine*, Schattauer Verlag, 1993, S.120-130.
- [Combi/Shahar 97] Combi, C., Shahar, Y.: Temporal Reasoning and Temporal Data Maintenance in Medicine: Issues and Challenges. In: *Computers in Biology and Medicine*, Vol. 27, No. 5, Elsevier Science Publisher, 1997, S. 363-368.

- [Combi et al. 95] Combi, C., Pincioli, F., Pozzi, G.: Managing Different Time Granularities of Clinical Information by an Interval-based Temporal Data Model. In: *Methods of Information in Medicine* 34, Schattauer Verlag, 1995, S.458-474.
- [Conklin 95] Conklin, D.: Machine Discovery of Protein Motifs. In: *Machine Learning*, 21, Kluwer Academic Publishers, Boston, 1995, S. 125-150.
- [Cooper et al. 97] Cooper, G.F., Aliferis, C.F., Ambrosino, R., Aronis, J., Buchanan, B.G., Caruana, R., Fine, M.J., Glymour, C., Gordon, G., Hanusa, B.H., Janosky, J.E., Meek, C., Mitchell, T., Richardson, T., Spirtes, P.: An evaluation of machine-learning methods for prediction pneumonia mortality. In: *Artificial Intelligence in Medicine* 9, Elsevier Science, 1997, S. 107-138.
- [Devijver/Kittler 82] Devijver, P.R., Kittler, J.: *Pattern Recognition: A Statistical Approach*. Prentice-Hall, Englewood Cliffs, New Jersey, 1982.
- [Diekmann 95] Diekmann, A.: *Empirische Sozialforschung - Grundlagen, Methoden, Anwendungen*. Rowohlt Taschenbuch Verlag, Hamburg, 1995.
- [Dorffner et.al.93] Dorffner, G., Rappelsberger, P., Flexer, A.: Using Selforganizing Feature Maps to Classify EEG Coherence Maps. In: S. Gielen, B. Kappen (Eds.): *Intl. Conference on Artificial Neural Networks (ICANN 93)*, Amsterdam, Springer Verlag, London, 1993, S. 882-887.
- [Duda/Hart 73] Duda, R., Hart, P.: *Pattern Classification and Scene Analysis*. Wiley, New York, 1973.
- [Duden 90] *Der Große Duden*, Bibliographisches Institut, Mannheim, 1990.
- [Elo et.al. 92] Elo, P., Saarinen, J., Värri, A., Nieminen, H., Kaski, K.: Classification of Epileptic EEG by using Self-Organizing Maps. In: I. Aleksander, J. Taylor (Eds.): *Artificial Neural Networks*, 2, Elsevier Science Publisher, 1992, S. 1147-1150.
- [Foslien/Samad 95] Foslien, W., Samad, T.: Fuzzy Controller Synthesis with Neural Network Process Models. In: S. Goonatilake, S. Khebal (Eds.): *Intelligent Hybrid Systems*, Wiley&Sons, New York, 1995, S. 23-46.
- [Fu 74] Fu, K.S.: *Syntactic Methods in Pattern Recognition*. Academic Press, New York, 1974.
- [Fu 82] Fu, S.: *Syntactic Pattern Recognition and Applications*. Prentice-Hall, Englewood-Cliffs, N.J., 1982.

- [Fukunaga 90] Fukunaga, K.: Introduction to Statistical Pattern Recognition. 2nd Edition, Academic Press, Inc., Boston, 1990.
- [Gade et al. 94] Gade, J., Rosenfalk, A., Bendtsen, I.: Detection of EEG Patterns Related to Nocturnal Hypoglycemia. In: Methods of Information in Medicine, 33, Schattauer Verlag, 1994, S. 153-156.
- [Gamper/Nejdl 97] Gamper, J., Nejdl, W.: Abstract temporal diagnosis in medical domains. In: Artificial Intelligence in Medicine 10, Elsevier Science Publisher, 1997, S. 209-234.
- [Gonzalez/Thomason 78] Gonzalez, R.C., Thomason, M.G.: Syntactic Pattern Recognition, An Introduction. Addison-Wesley, London, 1978.
- [Goonatilake/Khebal 95] Goonatilake, S., Khebal, S.: Intelligent Hybrid Systems: Issues, Classifications and Future Directions. In: S. Goonatilake, S. Khebal (Eds.): Intelligent Hybrid Systems, Wiley&Sons, New York, 1995.
- [Guimarães/Korus 92] Guimarães, G., Korus, D.: Selbstorganisierende Neuronale Netze auf Transputern, Proc. Transputer Anwender Treffen, TAT 92, Aachen, 1992, S. 75-76.
- [Guimarães/Ultsch 97] Guimarães, G., Ultsch, A.: A Symbolic Description for Patterns using Definitive Clause Grammars. In: R. Klar, O. Opitz (Eds.): Classification and Knowledge Organization, Proc. of the 20th Annual Conference of the Gesellschaft für Klassifikation, March 6-8 1996, University of Freiburg, 1997, S. 105-111.
- [Habel et al. 93] Habel, C., Herweg, M., Pribbenow, S.: Wissen über Raum und Zeit. In: G. Götz (Hrsg.): Einführung in die künstliche Intelligenz. Addison-Wesley, Bonn, 1993.
- [Haimowitz/Kohane 96] Haimowitz, I.J., Kohane, I.S.: Managing temporal worlds for medical trend diagnosis. In: Artificial Intelligence in Medicine 8, Elsevier Science Publisher, 1996, S. 299-321.
- [Harris 93] Harris, T.: A Kohonen S.O.M. based, Machine Health Monitoring System which enables Diagnosis of Faults not seen in the Training Set. Proc. Intl. Joint Conf. on Neural Networks (IJCNN 93), Nagoya, 1993, S. 947-950.
- [Hartigan/Wong 79] Hartigan, J.A., Wong, M.A.: A k-means-Clustering Algorithm, Applied Statistics, 28, 1979, S. 100-108.
- [Hartung 91] Hartung, J.: Statistik, 8. Aufl., Oldenbourg Verlag, 1991.

- [Hartung/Elpelt 84] Hartung, J., Elpelt, B.: *Multivariate Statistik*, Oldenbourg Verlag, 1984.
- [Hecht-Nielsen 90] Hecht-Nielsen, R.: *Neurocomputing*. Addison-Wesley, Reading, Mass., 1990.
- [Heikkonen et al. 93] Heikkonen, J., Koikkalainen, P., Oja, E.: From Situations to Actions: Motion Behavior Learning by Self-Organization. In: S. Gielen, B. Kappen (Eds.): *Intl. Conference on Artificial Neural Networks (ICANN 93)*, Amsterdam, 1993, S. 262-267.
- [Heskes/ Kappen 93] Heskes, T.M., Kappen, B.: Error potential for self-organization. In: *Proc. Intl. Conference on Neural Networks (ICNN 93)*, IEEE Service Center, Piscataway, NJ, 1993, Vol. III, S. 1219-1223.
- [Hiltunen et.al. 93] Hiltunen, T., Leinonen, L., Kangas, J.: Visualization and Classification of Voice Quality with the Self-Organizing Map. In: S. Gielen, B. Kappen (Eds.): *Intl. Conf. on Artificial Neural Networks (ICNN 93)*, Amsterdam, September, Springer Verlag, London, 1993, S. 420.
- [Honavar/Uhr 95] Honavar, V., Uhr, L.: Integrating Symbol Processing Systems and Connectionist Networks. In: Goonatilake, S., Khebal, S. (Eds.): *Intelligent Hybrid Systems*, Wiley&Sons, 1995, S. 177-208.
- [Hung/Lin 94] Hung, H.L., Lin, W.C.: Dynamic Hierarchical Self-Organizing Neural Networks. In: *Proc. Intl. Conf. on Neural Networks (ICNN 94)*, Vol. 1, Piscataway, NJ, IEEE Service Center, 1994, S. 627 - 632.
- [Ichiki et al. 91] Ichiki, H., Hagiwara, M., Nakagawa, M.: Self-Organizing Multi-Layer Semantic Maps. In: *Proc. Intl. Joint Conf. on Neural Networks (IJCNN 91)*, Seattle, Vol. I, 1991, S. 357-360.
- [Iivarin et.al.94] Iivarin, J., Valkealahti, K., Visa, A., Simula, O.: Feature Selection with Self-Organizing Feature Map. In: M. Marinaro, P.G. Morasso (Eds.): *Intl. Conf. on Artificial Neural Networks, Italy*, Springer Verlag, 1994, S. 334-337.
- [Jiang et al. 94] Jiang, X., Gong, Z., Sun, F., Chi, H.: A Speaker Recognition System Based on Auditory Model. In: *World Congress on Neural Networks (WCNN 94)*, Vol. 4, Hillsdale, NJ., Lawrence Erlbaum, 1994, S. 595-600.
- [Joutsiniemi et al. 95] Joutsiniemi, S.L., Kaski, S., Larsen, T.A.: Self-Organizing Map in Recognition of Topographic Patterns of EEG Spectra. *IEEE Transactions on Biomedical Engineering*, Vol. 42, No. 11, November 1995, S. 1062-1068.

- [Juhola 91] Juhola, M.: A Syntactic Analysis Method for Sinusoidal Tracking Eye Movements. In: *Computers and Biomedical Research* 24, 1991, S. 222-233.
- [Juhola/Grönfors 91] Juhola, M., Grönfors, T.: A scheme of inference of regular grammars for the syntactic pattern recognition of saccadic eye movements. In: *Artificial Intelligence in Medicine* 3, Elsevier, 1991, S. 87-93.
- [Juon 85] Juon, C.: Fehler- und flektionstolerante Ähnlichkeitsalgorithmen für natürlichsprachige Wörter. ETH Zürich, Insitut für Informatik, Diplomarbeit, 1985.
- [Kallio et.al. 91] Kallio, K., Haltsonen, S., Paajanen, E., Rosqvist, T., Katila, T., Karp, P., Malmberg, P., Piirilä, P., Sovijärvi, A.R.A: Classification of Lung Sounds by using Self-Organizing Feature Maps. In: T. Kohonen, K. Mäkisara, O. Simula, J. Kangas (Eds.): *Artificial Neural Networks*, Elsevier Science Publisher, 1991, S. 803 - 808.
- [Kanal/Dattatreya 92] Kanal, L.N., Dattatreya , G.R.: Pattern Recognition. in S.C. Shapiro (Ed.): *Encyclopedia of Artificial Intelligence*, Vol. 2, John Wiley&Sons, 1992.
- [Kangas 92] Kangas, J.: Temporal Knowledge in Locations of Activations in a Self-Organizing Map. In: I. Aleksander, J. Taylor (Eds.): *Artificial Neural Networks*, 2, Elsevier Science Publisher, 1992, S. 117-120.
- [Kasabov/Peev 94] Kasabov, N.,Peev, E.: Phoneme Recognition with Hierarchical Self Organized Neural Networks and Fuzzy Systems - A Case Study, In: M. Marinaro, P.G. Morasso (Eds.): *Intl. Conf. on Artificial Neural Networks (ICANN 94)*, Italy, Springer, 1994, S. 201-204.
- [Kaski 97] Kaski, S.: Data Exploration Using Self-Organizing Maps. *Acta Polytechnica Scandinavia, Mathematics, Computing and Management in Engineering*, Series No. 82, PhD Thesis, Helsinki University of Technology, 1997.
- [Kaski/ Joutsiniemi 93] Kaski, S., Joutsiniemi, S.L.: Monitoring EEG Signal with the Self-Organizing Map. In: S. Gielen, B. Kappen (Eds.): *Intl. Conf. on Artificial Neural Networks (ICANN 93)*, Amsterdam, Springer Verlag, London, 1993, S.974-977.

- [Kaski/ Kohonen 96] Kaski, S., Kohonen, T.: Exploratory Data Analysis by the Self-Organizing Map: Structures of the Welfare and Poverty in the World. In: A. P. N. Refenes, Y. Abu-Mostafa, J. Moody, A. Weigend (Eds.): Neural Networks in Financial Engineering. Proc. of the Intl. Conf. on Neural Networks in the Capital Markets, London, England, 11-13. October, 1995, World Scientific, Singapore, 1996, S. 498-507.
- [Kasslin et.al. 92] Kasslin, M., Kangas, J., Simula, O.: Process State Monitoring using Self-Organizing Maps. In: I. Aleksander, J. Taylor (Eds.): Artificial Neural Networks, 2, Elsevier Science Publisher, 1992, S. 1531-1534.
- [Kemke/Wichert 93] Kemke, C., Wichert, A.: Hierarchical Self-Organizing Feature Maps for Speech Recognition. In: Proc. of the World Congress on Neural Networks (WCNN 93), Hillsdale, Vol. III, 1993, S. 45-47.
- [Kerber et al. 95] Kerber, R., Livezey, B., Simoudis, E.: A Hybrid System for Data Mining. In: S. Goonatilake, S. Khebal (Eds.): Intelligent Hybrid Systems, Wiley&Sons, New York, 1995, S.121-142.
- [Kita/Nishikawa 93] Kita, H., Nishikawa, Y.: A Neural Network Model of Tonic Map Formation based on the Temporal Theory of Auditory Sensation. Proc. of the World Congress on Neural Networks (WCNN 93), Hillsdale, Vol. II, 1993, S. 413-418.
- [Klimasauskas 95] Klimasauskas, C.C.: Using Fuzzy Pre-processing with Neural Networks for Chemical Process Diagnostic Problems. In: S. Goonatilake, S. Khebal (Eds.): Intelligent Hybrid Systems, Wiley&Sons, New York, 1995, S. 143-152.
- [Kleine et al. 96] Kleine, T.O., Simon, J., Farsch, S., Pietzuch, W., Korus, D., Guimarães, G., Ultsch, A.: Integration von Neuronalen Netzen und wissenbasierten Systemen in der Medizin am Beispiel der Liquordiagnostik, Vortrag, Workshop Chemie & Informatik: Klassifizierung und Vorhersage von Moleküleigenschaften, Tübingen, 4. Oktober 1996.
- [Koh et.al. 95] Koh, J., Suk, M., Bhandarkar, S.M.: A Multilayer Self-Organizing Feature Map for Range Image Segmentation. Neural Networks, Vol.8, No. 1, Elsevier Science Publisher, 1995, S. 67-86.
- [Kohonen 82] Kohonen, T.: Clustering, taxonomy and topological maps of patterns. In: Proc. Intl. Conf. on Pattern Recognition (ICPR 82), IEEE Computer Soc. Press, Washington D.C., 1982, S. 114-128.

- [Kohonen 84] Kohonen, T.: Self-Organization and Associative Memory. Springer Series in Information Sciences 8, Springer Verlag, New York, 1984.
- [Kohonen 88] Kohonen, T.: The „Neural“ Phonetic Typewriter, In: Computer, 1988, S. 11-22.
- [Kohonen 89] Kohonen, T.: Speech Recognition based on Topology - Preserving Neural Maps. In: I. Aleksander (Ed.): Neural Computing Architectures, 1989, S. 26-40.
- [Kohonen 91] Kohonen, T.: The Hypermap Architecture. In: T. Kohonen, K. Mäkisara, O. Simula, J. Kangas (Eds.): Artificial Neural Networks, Elsevier Science Publishers, North Holland, 1991, S. 1357-1360.
- [Kohonen 94] Kohonen, T.: What Generalizations of the Self-Organizing Map Make Sense?. In: M. Marinaro, P.G. Morasso (Eds.): Intl. Conf. on Artificial Neural Networks, 1994, S. 292-297.
- [Kohonen 95] Kohonen, T.: Self-Organizing Maps, Springer Verlag, New York, 1995.
- [Koski et. al 95] Koski, A., Juhola, M. and Meriste, M.: Syntactic recognition of ECG signals by attributed finite automata. In: Pattern Recognition, The Journal of the Pattern Recognition Society, ISSN 0031-3203, Volume 28, Issue 12, December 1995, S. 1927-1940.
- [Kosko 92] Kosko, B.: Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence. Prentice-Hall Intl., 1992.
- [Kowalsky/Sergot 86] Kowalsky, R., Sergot, M.: A Logik-based Calculus of Events. In: New Generation Computing , 4, 1986, S. 67-95.
- [Kröse/Eecen 94] Kröse, B.J.A, Eecen, M.: Self-Learning Maps for Path Planning in Sensor Space. In: M. Marinaro, P.G. Morasso (Eds.): Intl. Conf. on Artificial Neural Networks (ICANN 94), Italy, Springer Verlag, 1994, S. 1303-1306.
- [Kurfess 95] Kurfess, F.: Wissensverarbeitung mit Neuronalen Netzen. In: Beiträge zur Herbstschule Konnektionismus und Neuronale Netze. (HeKoNN), 1995.
- [Lampinen 91] Lampinen, J.: Distortion Tolerant Pattern Recognition using Invariant Transformations and Hierachical SOFM Clustering. In: T. Kohonen, K. Mäkisara, O. Simula, J. Kangas (Eds.): Artificial Neural Networks, Elsevier Science Publisher, North Holland, 1991, S. 99-104.

- [Lampinen/Oja 89] Lampinen, J., Oja, E.: Self-Organizing Maps for Spatial and Temporal AR Models. In: The 6th Scandinavian Conference on Image Analysis, Oulu, Finland, 1989, S. 19-22.
- [Lapedes/Farber 87] Lapedes, A.S., Farber, R.M.: Nonlinear signal processing using neural networks: prediction and system modelling. Technical Report LA-UR-87-2662 Los Alamos National Laboratory, 1987.
- [Leinonen et al. 93] Leinonen, L., Hiltunen, T., Torkkola, K., Kangas, J.: Self-organized Acoustic Feature Map in Detection of Forcative-Vowel Coarticulation. In: J. Acoust. Soc. Am. (6), 1993, S. 3468-3474.
- [Leinonen et al. 92] Leinonen, L., Kangas, J., Torkkola, K., Juvas, A.: Dysphonia Detected by Pattern Recognition of Spectral Composition. In: Journal of Speech and Hearing Research 35, April, 1992, S. 287 - 295.
- [Lemon 88] Lemon, R.: The Output Map of the Primate Motor Cortex. In: Trends in Neural Science, Vol. 11, 11, S. 501-506.
- [Lin et al. 97] Lin, S., Si, J., Schwartz, A.B.: Self-Organization of Firing Activities in Monkey's Motor Cortex: Trajectory Computation from Spike Signals. In: Neural Computation 9, 1997, S.607-621.
- [Lowe/Webb 90] Lowe, D., Webb, A.R.: Exploiting prior knowledge in network optimization: an illustration from medical prognosis. In: Computation in Neural Systems 1 (3), 1990, S. 299-323.
- [Masters 93] Masters, T.: Signal and Image Processing with Neural Networks. John Wiley & Sons, 1993.
- [McDermot 82] McDermot, D: A Temporal Logic for Reasoning about Processes and Plans. Cognitive Science, 6, 1982, S. 101-155.
- [McDermott/Bachant 84] McDermott, J., Bachant, J.: R1 Revisited: Four Years in the Trenches. AI Magazine, No. 3, 1984, S. 21-32.
- [Midenet/Grumbach 94] Midenet, S., Grumbach, A.: Learning Associations by Self-Organization: The LASSO Model. In: Neurocomputing 6, Elsevier Science Publisher, 1994, S. 343-361.
- [Miller/Sittig 90] Miller, P.L., Sittig, D.F.: The evaluation of clinical decision support systems: what is necessary versus what is interesting. Med. Inform., Vol. 15, No.3, 1990, S. 185-190.
- [Montana/Davis 89] Montana, D., Davis, L.: Training Feedforward Neural Networks using Genetic Algorithms. In: Proc. of 11th Intl. Joint Conference on Artificial Intelligence, 1989, S. 762-767.

- [Müller et al. 96] Müller, R., Thews, O., Rohrbach, C., Sergl, M., Pommerening, K.: A Graph-Grammar Approach to Represent Causal, Temporal and Other Contexts in an Oncological Patient Record. In: *Methods of Information in Medicine*, F.K. Schattauer Verlag, 1996, S. 127-141.
- [Mujunen et.al. 93] Mujunen, R., Leinonen, L, Kangas, J., Torkkola, K.: Acoustic Pattern Recognition of /s/ Misarticulation by the Self-Organizing Map. In: *Folia Phoniatr.*, 45, 1993, S. 135 - 144.
- [Nauck et al. 94] Nauck, D., Klawonn, F., Kruse, R.: *Neuronale Netze und Fuzzy-Systeme. Grundlagen des Konnektionismus, Neuronaler Fuzzy-Systeme und der Kopplung mit wissensbasierten Methoden.* Vieweg Verlag, Wiesbaden, 1994.
- [Naumann/Langer 94] Naumann, S., Langer, H.: *Parsing - Eine Einführung in die maschinelle Analyse natürlicher Sprache.* B.G. Teubner, Stuttgart, 1994.
- [Niemann 90] Niemann, H.: *Pattern Analysis and Understanding.* Springer Series in Information Sciences 4, Springer Verlag, Berlin, 2nd. edition, 1990.
- [Niemann 95] Niemann, H.: *Skriptum zur Mustererkennung.* FAU Erlangen-Nürnberg, 1995.
- [Niemann/Bunke 87] Niemann, H., Bunke, H.: *Künstliche Intelligenz in Bild- und Sprachanalyse.* Teubner Verlag, 1987.
- [Nykänen et al. 91] Nykänen, P., Chowdhury, S., Wigeritz, O.: Evaluation of decision support systems in medicine. In: *Computer Methods and Programs in Biomedicine*, 34, 1991, 229-238.
- [O'Neil/Glowinski 90] O'Neil, M., Glowinsky, A.: Evaluating and validating very large knowledge-based systems. In: *Med. Inform.*, Vol. 15, No.3, 1990, S. 237 - 251.
- [Ohmann/Belenky 96] Ohmann, C., Belenky, G.: *Leitfaden zur Evaluation von Wissensbasen.* Bericht des MEDWIS-Arbeitskreis "Evaluation", 1996.
- [Ohmann et al. 95] Ohmann, C., Platen, C., Belenky, G., Franke, C., Otterbeck, R., Lang, K., Röher, H.D.: *Expertensystem zur Unterstützung von Diagnosestellung und Therapiewahl bei akuten Bauchschmerzen.* In: *Informatik, Biometrie und Epidemiologie in Medizin und Biologie* 26 (3), Eugen Ulmer Verlag, 1995, S. 262-274.
- [Oppenheim/Willsky 92] Oppenheim, A.V., Willsky, A.S.: *Signale und Systeme, Lehrbuch*, 2. Aufl., VCH, Weinheim, 1992.

- [Palm et al. 94] Palm, G., Ultsch, A., Goser, K., Rückert, U.: Knowledge Processing in Neural Architecture, In: VLSI for Neural Networks and Artificial Intelligence, New York, 1994, S. 207-216.
- [Palm et al. 95] Palm, G.P., Schwenker, F., Sommer, F. T.: Associative Memory Networks and Sparse Similarity Preserving Codes. In: V. Cherkassky; H. Wechsler (Eds.): Neural Networks: Theory and Pattern Recognition Applications. Springer, NATO ASI Series F, Springer, 1995.
- [Pao 89] Pao, Y.-H.: Adaptive Pattern Recognition and Neural Networks. Addison-Wesley, 1989.
- [Penzel 95] Penzel, T.: Zur Pathophysiologie der Interaktion von Schlaf, Atmung und Kreislauf - Konzepte der Kardiorespiratorischen Polysomnographie. Habilitationsschrift, Universität Marburg, 1995.
- [Penzel et al. 87] Penzel, T., Peter, J.H., Wichert, P.V.: Konzepte für die rationelle Erfassung und Auswertung polysomnographischer Daten bei Patienten mit schlafbezogenen Atemregulationsstörungen. In: Prax. Klin. Pneumol. 41, 1987, S. 411-416.
- [Penzel et al. 90] Penzel, T., Amend, G., Meinzer, K., Peter, J.H., von Wichert, P.: MESAM: A Heart Rate and Snoring Recorder for Detection of Obstructive Sleep Apnea. In: Sleep, 13, 1990, S. 175-182.
- [Penzel et al.91] Penzel, T., Stephan, K., Kubicki, S., Herrmann, W.M.: Integrated Sleep Analysis, with Emphasis on Automatic Methods. In: R. Degen, E.A. Rodin (Eds.): Epilepsy, Sleep and Sleep Deprivation, 2nd ed. (Epilepsy Res. Suppl. 2), Elsevier Science Publisher, 1991, S. 177-204.
- [Penzel/Peter 92] Penzel, T., Peter, J.H.: Design of an Ambulatory Sleep Apnea Recorder. In: H.T. Nagle, W.J. Tompkins (Eds.): Case Studies in Medical Instrument Design, The Institute of Electrical and Electronics Engineers Inc, New York, 1992, S. 171-179.
- [Penzel/Petzold 89] Penzel, T.,Petzold, J.: A New Method for the Classification of Subvigil Stages, using Fourier Transform, and its Application to Sleep Apnea. In: Comput. Biol. Med. Vol. 19, No.1, Pergamon Press, 1989, S. 7-34.
- [Pereira/Shieber 87] Pereira, F.C.N., Shieber, S.M.: Prolog and Natural-Language Analysis. Lecture Notes, Number 10, Center for the Study of Language and Information, 1987.

- [Pereira/Warren 80] Pereira, F.C.N., Warren, D.: Definitive Clause Grammars for Language Analysis - A Survey of the Formalism and a Comparison with Augmented Transition Networks. In: Artificial Intelligence 13, 1980, S. 231-278.
- [Peter 91] Peter, J.H.: Chronobiologie und Schlaf. In: Internist 32, Springer Verlag, 1991, S. 363-379.
- [Peter 91a] Peter, J.H.: Störungen der Atmungsregulation. In: H. Hornbostel, W. Kaufmann, W. Siegenthaler (Eds.): Innere Medizin in Praxis und Klinik, Band I: Herz, Gefäße, Atmungsorgane, Endokrines System, 4. Aufl., Georg Thieme Verlag, New York, 1991, S. 262-280.
- [Principe/Wang 95] Principe, J.C., Wang, L.: Non-Linear Time Series Modeling with Self-Organizing Feature Maps. In: Proc. IEEE Workshop on Neural Networks for Signal Processing, Piscataway, NJ, IEEE Service Center, 1995, S. 11 - 20.
- [Privitera/Morasso 93] Privitera, C.M., Morasso, P.: A new Approach to Storing Temporal Sequences. In: Proc. Intl. Joint Conf. on Neural Networks, Nagoya, 1993, S. 2745 - 2748.
- [Puppe 91] Puppe, F.: Einführung in Expertensysteme. Springer Verlag, Berlin, 2. Aufl., 1988.
- [Ritter 94] Ritter, H.: Parametrized Self-Organizing Maps for Vision Learning Tasks. In: M. Marinaro, P.G. Morasso (Eds.): Proc. Intl. Conference on Artificial Neural Networks (ICANN 94), Italy, Springer Verlag, 1994, S.803-810.
- [Ritter/Kohonen 89] Ritter, H., Kohonen, T.: Self-Organizing Semantical Maps, Biological Cybernetics 61, 1989, S. 241-254.
- [Ritter et al. 92] Ritter, H., Martinetz T., Schulen, K.: Neuronale Netze - Eine Einführung in die Neuroinformatik selbstorganisierender Netzwerke, Addison-Wesley, Bonn, 1992.
- [Rodriguez et al. 93] Rodriguez, M.J., Pozo, F., Arredondo, M.T.: Use of Unsupervised Neural Networks for Classification of Blood Pressure. Proc. of the World Congress on Neural Networks (WCNN 93), Hillsdale, Vol. II, 1993, S. 469-473.
- [Röske 97] Röske, F.: Wasserstandvorhersage mittels neuronaler Netze. Dissertation, Hamburg, 1997.
- [Rojas 93] Rojas, R.: Theorie der neuronalen Netze - eine systematische Einführung. Springer Verlag, Berlin, 1993.

- [Roos et al.93] Roos, M., Althaus, W., Rhiel, C., Penzel, T., Peter, J.H., von Wichert, P.: Vergleichender Einsatz von MESAM IV und Polysomnographie bei schlafbezogenen Atmungsstörungen (SBAS). In: Pneumologie 47, 1993, S. 112-118.
- [Rossi-Mori et al. 90] Rossi-Mori, A.,Pisanelli, D.M., Ricci, F.L.: Evaluating stages and design steps for knowledge-based systems in medicine. Med. Inform., Vol. 15, No. 3,1990, S. 191 - 204.
- [Rumelhart/McClelland 86] Rumelhart, D.E., McClelland, J.L.: Parallel Distributed Processing. MIT Press, Cambridge, 1986.
- [Sander et al. 95] Sander, P., Stucky, W., Herschel, R.: Automaten, Sprachen, Berechenbarkeit. In: W. Stucky (Hrsg.): Grundkurs Angewandte Informatik IV, B.G. Teubner, Stuttgart, 1995.
- [Sarle 94] Sarle, W.S.: Neural Networks and Statistical Models. In: Proc. of the Nineteenth Annual SAS Users Group Intl. Conf., April, 1994 , S. 1-13.
- [Schalkoff 92] Schalkoff, R.: Pattern Recognition, Statistical, Structural and Neural Approaches. John Wiley & Sons, New York, 1992.
- [Scherer/Schlageter 95] Scherer, A., Schlageter, G.: A Multi-Agent Approach for the Integration of Neural Networks and Expert System. In: S. Goonatilake, S. Khebal (Eds.): Intelligent Hybrid Systems, Wiley&Sons, New York, 1995, S.153-174.
- [Schlittgen/Streitberg 94] Schlittgen, R.,Streitberg, B.H.J.: Zeitreihenanalyse. In: R. Oldenbourg Verlag, 5. Auflg., München ,1994.
- [Schneider 91] Schneider, H.-J.: Lexikon der Informatik und Datenverarbeitung. 3. Aufl., R. Oldenbourg Verlag, München, 1991.
- [Schweizer et al. 94] Schweizer, M; Föhn, P.; Schweizer, J.; Ultsch, A.: A Hybrid Expert System for Avalanche Forecasting. In: W. Schertler, B. Schmid, A.M. Tjoa, H. Werther (Eds.): Information and Communications Technologies in Tourism, Springer, Wien, S. 148-153.
- [Scott et al. 91] Scott, A.C., Clayton, J.E., Gibson, E.L.: A Practical Guide to Knowledge Acquisition. Addison-Wesley, New York, 1991.
- [Searls 95] Searls, D.B.: String Variable Grammar: A Logic Grammar Formalism for the Biological Language of DNA. In: The Journal of Logic Programming, Vol. 24, 1995, S.73-102.

- [Searls/Dong 93] Searls, D., Dong, S.: A Syntactic Pattern Recognition System for DNA Sequences. In: The 2nd Intl. Conf. on Bioinformatics, Supercomputing, Complex Genome Analysis, June 4-7, 1992, St. Petersburg Beach, Florida, 1993, S. 89-101.
- [Sestito/Dillon 94] Sestito, S., Dillon, T.: Automated Knowledge Acquisition. Prentice Hall, Australia, 1994.
- [Shahar 97] Shahar, Y.: A framework for knowledge-based temporal abstraction. In: Artificial Intelligence 90, Elsevier Science, 1997, S.79-133.
- [Shahar/Musen 96] Shahar, Y., Musen, M.A.: Knowledge-based temporal abstraction in clinical domains. In: Artificial Intelligence in Medicine 8, Elsevier Science, 1996, S.267-298.
- [Siemon/Ultsch 92] Siemon, H.P., Ultsch, A.: Kohonen Neural Networks for Exploratory Data Analysis: In: Proc. Conf. Soc. for Information and Classification, Dortmund, April 1992.
- [Siregar/Sinteff 96] Siregar, P., Sinteff, J.P.: Introducing spatio-temporal reasoning into the inverse problem in electroencephalography. In: Artificial Intelligence in Medicine 8, Elsevier Science, 1996, S.97-122.
- [So/Chan 94] So, Y.T., Chan, K.P.: Topological Network by the Existence of Lateral Feedback. In: Proc. Intl. Conference on Neural Networks (ICNN 94), Vol II, 27-29 June, Orlando, 1994, S. 681-685.
- [Sparks/Nelson 87] Sparks, D.L., Nelson, J.S.: Sensory and Motor Maps in the Mammalian Superior Colliculus. TINS 10, 1987, S. 312-317.
- [Sterling/Shapiro 86] Sterling, L., Shapiro, E.: The Art of Prolog, Advanced Programming Techniques, MIT Press, Cambridge, 1986.
- [Suppes et. al 95] Suppes, P., Böttner, M., Liang, L.: Comprehension Grammars Generated from Machine Learning of Natural Languages, Machine Learning, Volume 19, 1995, S. 133.
- [Tanimoto 90] Tanimoto, S. L.: KI: Die Grundlagen. R. Oldenbourg Verlag, München, 1990.
- [Tavan et al. 90] Tavan, P., Grubmüller, H., Kühnel, H.: Self-organization of assoziative memory and pattern classification: recurrent signal processing on topological feature maps. In: Biol. Cybernetics, 64, 1990, S. 95-105.

- [Tirri 95] Tirri, H.: Replacing the Pattern Matcher of an Expert System with a Neural Network. In: S. Goonatilake, S. Khebal (Eds.): Intelligent Hybrid Systems, Wiley&Sons, New York, 1995, S.47-62.
- [Tou/Gonzalez 74] Tou, J.T., Gonzalez, R.C.: Pattern Recognition Principles. Addison Wesley, 1974.
- [Tryba/Goser 91] Tryba, V.,Goser, K.: Self-Organizing Feature Maps for Process Control in Chemistry. In: T. Kohonen, K. Mäkisara, O. Simula, J. Kangas (Eds.): Artificial Neural Networks, Elsevier Science Publisher, North Holland, 1991, S. 847-852.
- [Tuya et.al. 93] Tuya, J.,Arias, E., Sanchez, L., Corrales, J.A.: Combination of Self-Organizing Maps and Multilayer Perceptrons, for Speaker Independent Isolated Word Recognition. In: J. Mira, J. Cabestany, A. Prieto (Eds.): New Trends in Neural Computation, Intl. Workshop on Artificial Neural Networks, Spain, Springer Verlag, Berlin,1993, S. 550-555.
- [Ultsch 87] Ultsch, A.: Control for Knowledge-based Information Retrieval, Informatik-Dissertationen ETH Zürich, Verlag der Fachvereine Zürich, 1987.
- [Ultsch 88] Ultsch, A.: Einführung in konnektionistische Modelle der Künstlichen Intelligenz. Fachbereich Informatik, 1988.
- [Ultsch 91] Ultsch, A.: Konnektionistische Modelle und ihre Integration mit wissensbasierten Systemen. Forschungsbericht Nr. 396, Institut für Informatik, Universität Dortmund, Februar, Dortmund, Habilitationsschrift, 1991.
- [Ultsch 92] Ultsch, A.: Self-Organizing Neural Networks for Visualization and Classification. In: Proc. Conf. Soc. Information and Classification, Dortmund, April, 1992.
- [Ultsch 93] Ultsch, A.: Self-Organized Feature Maps for Monitoring and Knowledge Acquisition of a Chemical Process, Gielen, S., Kappen, B. (Eds.): Proc. International Conference on Artificial Neural Networks (ICANN 93), Amsterdam, September 1993. Springer-Verlag, S. 864-867.
- [Ultsch 93a] Ultsch, A.: Knowledge Extraction from Self-organizing Neural Networks, In: O. Opitz, B. Lausen and R. Klar, (Eds.) Information and Classification, Berlin, Springer Verlag, 1987, S. 301-306.

- [Ultsch 94] Ultsch, A.: The Integration of Neural Networks with Symbolic Knowledge Processing. In: Diday et.al.: *New Approaches in Classification and Data Analysis*, Springer, 1994, S. 445-454.
- [Ultsch 94a] Ultsch, A.: Einsatzmöglichkeiten von Neuronalen Netzen im Umweltbereich, In: Page et al. (Eds.): *Umweltinformatik HdI 13.3*, Oldenbourg Verlag München, 1994, S. 201-226.
- [Ultsch 95] Ultsch, A.: Self Organizing Neural Networks perform different from statistical k-means clustering. In: *Tagungsband der Gesellschaft für Klassifikation*, Basel, 8.-10.März 1995.
- [Ultsch 95a] Ultsch, A.: Automatik Acquisition of Symbolic Knowledge from Subsymbolic Neural Networks: In: *FORWISS Report, KI-Workshop "Informationsfilterung"*, Erlangen, München Passau 1995.
- [Ultsch 96] Ultsch, A.: Hybride Systeme - der Einsatz von Konnektionistischen Modellen in wissensverarbeitenden Systemen. In: *Herbstschule Konnektionismus und Neuronale Netze (HeKoNN)*, Münster, 2.-6. Oktober, Münster, 1996.
- [Ultsch 96a] Ultsch, A.: Neuronale Netze ein Allheilmittel? Vortrag, 1996.
- [Ultsch 96b] Ultsch, A.: Eine unifikationsbasierte Grammatik zur Beschreibung von komplexen Mustern in multivariaten Zeitreihen. In: *persönliche Kommunikation mit A. Ultsch*, 1996.
- [Ultsch/Halmans 91] Ultsch, A., Halmans, G.: Data Normalization with Self-Organizing Feature Maps. In: *Proc. Intl Joint Conf. Neural Networks*, Seattle, WA, July 1991, Vol I, S. 403 - 407.
- [Ultsch/Guimarães 95] Ultsch, A., Guimarães, G. (Hrsg.): *Konnektionistische Modelle der KI. Beiträge zu Vorlesung Konnektionistische Modelle im WS 1994/95*, Universität Marburg, 1995.
- [Ultsch et al. 93] Ultsch, A., Guimarães, G., Korus, D., Li, H.: Knowledge Extraction from Artificial Neural Networks and Applications. *Transputer-Anwender-Treffen*, September 1993 Aachen, Tagungsband TAT'93, Springer Verlag, S. 194-203.
- [Ultsch et al. 94] Ultsch, A., Guimarães, G., Weber, V.: Self Organizing Feature Maps for Logical Unification. *Proc. of World Congress on Expert Systems (WCES 94)*, Lisboa, Januar 1994.
- [Ultsch et al. 94a] Ultsch, A; Korus, D., Guimarães, G., Li, H.: Integration von Neuronalen Netzen mit wissensbasierten Systemen. In: L. Cromme, J. Wille, T. Kolb (Eds.): *Proc. Cottbuser Workshop Anwendungen Neuro-*

naler Netze CoWAN 94, Oct. 4-6, 1994, Cottbus/F.R.G., Reihe Mathematik M-01/1995, S. 144-153.

- [Ultsch et al. 95] Ultsch, A.; Korus, D., Kleine, T.O.: Integration of Neural Networks and Knowledge-Based Systems in Medicine, 5th. Conf. Artificial Intelligence in Medicine Europe AIME'95, Pavia, Italy, June 1995, In: Barahona, P.; Stefanelli, M.; Wyatt, J. Artificial Intelligence in Medicine, Lecture Notes in Artificial Intelligence 934, Springer 1995, S. 425-426.
- [Ultsch et al. 95b] Ultsch, A.; Korus, D.; Wehrmann, A.: Neuronal Networks and their Rules for Classification in Marine Geology. In: Raum und Zeit in Umweltinformationssystemen, 9th Intl. Symposium on Computer Science for Environmental Protection CSEP '95, Vol. I, herausgegeben vom GI-Fachausschuß 4.6 „Informatik im Umweltschutz“ Band 7, Metropolis-Verlag, Marburg, 1995, S. 676-693.
- [Ultsch et al.96] Ultsch, A. Guimarães, G., Schmidt, W. : Classification and Prediction of Hail using Self-Organizing Neural Networks, Intl. Conference on Neural Networks, ICNN'96, Washington, 3-6 Juni, 1996.
- [Ultsch et al. 97] Ultsch, A.; Kleine, T.O.; Korus, D.; Farsch, S.; Guimaraes, G.; Pietzuch, W.; Simon, J.: Evaluation of Automatic and Manual Knowledge Acquisition for Cerebrospinal Fluid (CSF). In: E. Keravnu et al. (Eds.): Artificial Intelligence in Medicine, Lecture Notes in Artificial Intelligence 1211, Vol. 934, Springer Verlag, 1997, S. 110-121.
- [Utela et.al. 92] Utela, P.,Kangas, J., Leinonen, L.: Self-Organizing Map in Acoustic Analysis and On-Line Visual Imaging of Voice and Articulation. In: I. Aleksander, J. Taylor (Eds.): Artificial Neural Networks, 2, Elsevier Science Publisher, 1992, S. 791-794.
- [Valluy et al. 89] Valluy, L.,Nykänen, P., Rantanen, J., Salmela, J., Grönroos, P., Lumio, J.: An Approach to Combine Knowledge Validation & Evaluation with Development in Medical AI. Proc. of the Scandinavian Conference on Artificial Intelligence, Tampere, Finland, 1989, S. 753 - 764.
- [vanRijsbergen 79] van Rijsbergen, C.J.: Information Retrieval, 2nd ed., Butterwothsm, London, 1979.
- [Vila 94] Vila, L.: A Survey on Temporal Reasoning in Artificial Intelligence. In: Ai Communications, Vol. 7, Nr.1, March, 1994, S. 4-28.

- [Wachsmuth 93] Wachsmuth, I.: Expertensysteme, Planen und Problemlösen. In: G.Görz (Hrsg.): Einführung in die Künstliche Intelligenz, Addison-Wesley, New York, 1993, S.713-828.
- [Walter/Schulten 93] Walter, J.A., Schulten, K.J.: Implementation of Self-Organizing Neural Networks for Visual-Motor Control of an Industrial Robot. In: IEEE Transactions on Neural Networks, Vol. 4, No. 1, January, 1993, S. 86-95.
- [Wegener 93] Wegener, I.: Theoretische Informatik. Eine algorithmenorientierte Einführung. B.G. Teubner, Stuttgart, 1993.
- [Weierich/Rosenberg 94] Weierich, P., Rosenberg, M. von: Unsupervised Detection of Driving States with Hierarchical Self Organizing Maps. M. Marinaro, P.G. Morasso (Eds.): Intl. Conf. on Artificial Neural Networks (ICANN 94), Italy, Springer Verlag, 1994, S. 246-249.
- [Weigend et.al 90] Weigend, A.S.,Rumelhart, D.E.; Huberman, B.A.: Back-propagation, weight-elimination and time series prediction. In: D.S. Touretzky et. al. Proc. of the 1990 Connectionist Models Summer School, Morgan Kaufmann,1990.
- [Weigend/Gershenfeld 94] Weigend, A.S., Gershenfeld, N.A.: Time Series Prediction. Proc. of the NATO Advanced Research Workshop om Comparative Time Series Analysis in Santa Fe, New Mexico, May 14-17 of 1992, Addison Wesley, 1994.
- [Wermter 95] Wermter, S.:Hybride symbolische und subsymbolische Verarbeitung am Beispiel der Sprachverarbeitung. In: Beiträge zur Herbstschule Konnektionismus und Neuronale Netze (HeKoNN), 1995.
- [Wyatt/Spiegelhalter 90] Wyatt, J., Spiegelhalter, D.: Evaluating medical expert systems: what to test and how? In: Med. Inform., Vol. 15, No.3, 1990, S. 205 - 217.
- [Zadeh 65] Zadeh, L.A.: Fuzzy Sets. In: Information and Control 8, 1965, S. 338-353.
- [Zell 94] Zell, A.: Simulation Neuronaler Netze. Addison-Wesley, 1994.

Danksagung

Hiermit möchte ich allen herzlich danken, die mich bei der Anfertigung dieser Arbeit unterstützt haben.

Mein besonderer Dank gilt Herrn Prof. Dr. A. Ultsch für die inhaltliche Betreuung und die thematische Anregung sowie für die mir zur Verfügung gestellte Zeit zur Bearbeitung des interessanten Themengebietes Wissenskonversion für Zeitreihen aus dem Bereich der künstlichen Intelligenz und künstlichen neuronalen Netze. Mein herzlicher Dank gilt auch Herrn Prof. Dr. W. Urfer für seine Ratschläge für den Bereich Statistik. Besonderer Dank gilt Herrn Prof. Dr. J.H. Peter und Herrn Dr. T. Penzel für die mir zur Verfügung gestellten Daten. Dadurch erst ist es möglich geworden, meine Arbeit auf ein konkretes Beispiel anzuwenden.

Für zahlreiche inhaltliche Diskussionen und kritische Bemerkungen bedanke ich mich insbesondere bei Dieter Korus und Stefan Farsch und in der letzten Phase meiner Arbeit bei Susanne Rolf. Ein besonderer Dank geht auch an Silke Kley und Heinz Huemer für das Lesen des Manuskriptes meiner Arbeit.

An dieser Stelle möchte ich mich bei meinen Freunden bedanken, die durch ihre Unterstützung zum Gelingen dieser Arbeit beigetragen haben. Besonderer Dank gilt Consuela Pitters, Nelly Arbex, Birgit Huemer, Julio Perez und Ekrem Top. Außerdem möchte ich mich bei allen Mitgliedern der Marburger Chorgruppe Mandacaru für das gemeinsame Singen und Musizieren bedanken.

Ganz besonders möchte ich mich bei meinen Eltern und meinem Bruder bedanken, ohne deren liebevolle und stets hilfreiche Unterstützung diese Arbeit nicht möglich gewesen wäre. Letztendlich möchte ich bei meinem lieben Sohn Julian für seine Geduld und liebevolle Zuwendung in dieser Zeit bedanken.

Lebenslauf

Name		Gabriela Dick de Sousa Guimarães
Geboren am	02.07.1964	in Porto, Portugal
Familienstand		ein Sohn
Schulbildung	1970 - 1982	Grundschule und Gymnasium an der Deutschen Schule zu Porto in Portugal
Schulabschluß	Juni 1982	Abitur
Studium	1982 - 1990	Studium der Informatik mit Nebenfach Biologie an der Universität Dortmund
Berufstätigkeit	1991 - 1992	Wissenschaftliche Mitarbeiterin am Lehrstuhl Technik und Gesellschaft am Fachbereich Wirtschaft- und Sozialwissenschaften an der Universität Dortmund
	seit 1993	Wissenschaftliche Mitarbeiterin am Fachbereich Mathematik und Informatik der Philipps-Universität Marburg