

Artigo Original

Recebido em 04/08/2003 e aceito em 03/03/2004

Classificação de estados do ciclo sono-vigília em recém-nascidos por rede neural artificial de treinamento competitivo

Classifying the sleep-wake states cycle of neonates using self-organizing map

Ronaldo Bosignoli

Professor Adjunto
Departamento de Engenharia Elétrica-CECETEN
Universidade Severino Sombra – USS
Rua: Praça Martinho Nóbrega, 40
27700-000 – Vassouras – RJ
Tel: (24) 24718200
e-mail: rb@uss.br

Antonio Fernando Catelli Infantosi

Professor Titular
Programa de Engenharia Biomédica - COPPE/UFRJ
Cidade Universitária, Caixa Postal 68510,
21945-970, Rio de Janeiro, RJ
Tel: (21) 2562 8576 - Fax: (21) 2562 8591
e-mail: afci@peb.ufrj.br

Resumo

A ausência de alterações de estado no ciclo sono-vigília de recém-nascidos (NB), durante período de uma hora, indica possível disfunção neurológica e necessidade de investigação mais aprofundada. Com vistas a contribuir para este processo, Redes Neurais Artificiais (RNA) de treinamento não-supervisionado foram desenvolvidas para reconhecimento e classificação dos estados de sono ativo (SA), sono quieto (SQ) e vigília (VIG). As RNA foram estruturadas com a topologia de Mapa Auto-organizável de Características (MAOC) objetivando reconhecer e separar padrões com base no aprendizado competitivo entre os neurônios. No desenvolvimento e avaliação das RNA, 16 sinais fisiológicos de dez NB a termo foram utilizados. Como entradas dos MAOC, um projetado com 61 e outro com 27, parâmetros espectrais de potência média relativa nas faixas de frequência características de cada um dos sinais polissonográficos (Eletroencefalograma-EEG, Eletromiograma-EMG, Eletroculograma-EOG, Eletrocardiograma-ECG e ventilação) foram empregados. O MAOC de 61 parâmetros de entrada resultou em 77% de acurácia (AC), tendo como pior índice de desempenho a sensibilidade (S) de SQ (25%), embora S para VIG (79%) e SA (92%) tenha sido bem mais elevada. Para o MAOC de 27 entradas, AC diminuiu para 64%, sendo S para SQ ainda baixa (37%). Esses MAOC apresentam pior desempenho em comparação ao de RNA de treinamento supervisionado, indicando ser esse último tipo de rede mais adequado do que os MAOC na classificação de estados do ciclo sono-vigília de NB. Embora o MAOC possua inerentemente a capacidade de estabelecer uma rotulagem por meio dos agrupamentos resultantes, essa rede não parece ter sido capaz de capturar as características dos estados de SA, SQ e VIG, refletidas pelos parâmetros extraídos dos 16 sinais polissonográficos.

Palavras-chave: Classificação de estados de sono, EEG neonatal, Redes neurais artificiais, Treinamento competitivo.

Abstract

No change of the sleep-wake states during one hour indicates possible neurological disorder and must be properly investigated. To aid in the clinical decision making, Artificial Neural Networks (ANN) with unsupervised learning were developed aiming at recognizing and classifying some of the neonatal sleep-wake states, i.e. active sleep (SA), quiet sleep (SQ) and wakefulness (VIG). The topology of this competitive learning ANN was the Self-Organizing Map (SOM). For the development and validation of SOM, 16 physiological signals (electroencephalogram - EEG, electrooculogram - EOG, electrocardiogram - ECG, electromiogram - EMG and ventilation) from ten full-term neonates were acquired. The input parameters used were the spectral relative mean power within characteristic frequency ranges of each signal. Two SOM configurations were evaluated: one with 61 and another with 27 input

variables. The SOM of 61 input parameters resulted in an accuracy (AC) of 77%, being the sensitivity (S) for SQ (25%) the worst performance index, although S for VIG (79%) and SA (92%) has been much higher. For the SOM with 27 input parameters, AC decreased to 64% and S for SQ still remained very low (37%). In comparison with ANN supervised learning, the SOM showed much lower performance indicating that the first is more adequate to classify the neonatal sleep-wake states. In spite of the SOM has itself the capability to label different clusters, it seems that it has not adequately captured the characteristics of SA, SQ and VIG states, reflected through the parameters extracted from the 16 polysomnographic signals.

Key words: Artificial neural Networks, Classification neonatal EEG, Sleep-wake states, SOM

Extended Abstract

Introduction

In the diagnosis and prognosis of neonatal seizures, stability of the sleep-wake cycle is of vital importance. In the classification of Sleep-wake states (active sleep - SA, quiet sleep - SQ - and wakefulness - VIG), electroencephalographic signals (EEG) have been used (Scher et al., 1997). Other physiological signals might also be used, including behavioral variables (Stockard-Pope et al., 1992).

Using multivariate analysis applied to parameters extracted from EEG and EMG data from neonate human beings, Galhanone et al. (1996) have found 65% of accuracy. With this technique applied to physiological signals, Scher et al. (1996) obtained an accuracy of 93.3%. Artificial Neural Network (ANN) has been employed for classifying sleep-wake states in EEG from rats (Coimbra et al., 1995, Robert et al., 1997), from young or adult humans (Grozinger et al., 1997, Shimada et al., 2000) and from children with more than six month (Dorffner, 1997, Baumgart-Schmitt et al., 1998). According to Dorffner (1997), ANN with supervised learning (back-propagation algorithm, ANN-BP) improves the pattern recognition classification. Further, the self-organizing feature maps (SOM) applied to EEG parameters could be used just in special conditions.

More recently, three ANN-BP were developed by Bosignoli and Infantosi (2002) to evaluate SA, SQ and VIG from neonates signals. The approach of designing distinct ANN-BP, one for each sleep-wake state and trained separately, results in accuracy (AC) of 90% for SA, 93% for SQ and 95% for VIG. These high AC scores were achieved by taking into consideration other physiologic signals rather than just the EEG. In this work, SOM which uses a method that automatically creates classes by competitive learning will be developed aiming at recognizing and classifying sleep-wake states in human full term neonates. Further, the performance of SOM will be compared to that achieved with ANN-BP for the same database.

Materials and Methods

Polysomnographic data, EEG signals (Figure 1), electrooculogram - EOG, electrocardiogram - ECG, electromiogram - EMG and ventilation, were acquired from 10 healthy full-term neonates up to three days of birth. Using these sig-

nals and also the behavioral notation, the sleep wake states were classified by specialists (Table 1). The resulting relative duration of these states (Table 2), that is 52% SA, 33% SQ e 15% VIG (total of 4.2 h), were in accordance with Scher (1998). These signals were sampled at 256 Hz after anti-alias filtering and then the Bartlett's periodogram was estimated for each 5 s duration segments using the Discrete Fourier Transform of five consecutive epochs of 1 s.

The resulting 61 parameters of the relative mean power within characteristic frequency ranges of the 16 signals were taking as the input of SOM. Using an optimization process described by Bosignoli and Infantosi (2002), the input set of parameters was first reduced to 27 and then to just 16 (Table 3). The database consists of 3.4 hours sleep states. The relative power parameters of each 5 s signals, named vector, were extracted from the 2400 vectors. For testing and validation, these database was sub-divided in three equal sets of 496 vectors SA, 184 SQ e 120 VIG.

The topology initially adopted for the SOM was N inputs and M outputs in a bidimensional grid (5 x 5), with M = 25 output neurons full connected to the inputs (Fig. 2). The synaptic weight vectors between output and input neurons were initialized in a random manner and then normalized. The winning neuron at each step was established using the minimum distance Euclidean criterion. Weights were updated minimizing this distance with the learning-rate parameter beginning with 0.1 and thereafter decreasing to 0.01. The adopted rule of convergence was that the number of iterations must be 500M (Haykin, 2001). With this approach, the resulting self organization map indicates the existence of three clusters (Figure 3), each of them could be associated with the sleep-wake states (SA, SQ and VIG) of the neonates.

Results

Considering just the 61 parameters as input to the SOM, 77% accuracy (AC) was achieved, being the sensitivity (S) 25% for SQ, the worst accuracy measure of performance, 79% for VIG and 92% for SA. Developing another SOM and taking 27 parameters as input, AC decreased to 64% although an improvement of sensitivity for SQ (37%) has been achieved (Table 4). An increasing of the SOM performance (Table 5 and 6) has been obtained by reducing the classification of sleep-wake states only for two, SQ and VIG. In this case, using the SOM with 16 parameters as input, AC reaches 88% but the others indices are maintained.

Discussion and Final Comments

In comparison with ANN supervised learning, the SOM showed much lower performance indicating that the first is more adequate to classify the neonatal sleep-wake states. In spite of the SOM has itself the capability to label different clusters, it seems that it has not adequately captured the characteristics SA, SQ and VIG, reflected through the parameters extracted from the 16 polysomnographic signals. Nevertheless, the use of SOM can not be discarded since one could associate the SOM with ANN-BP to develop a system, for example, using the output of the ANN supervised learning (one for each state) as input to a self-organizing feature map.

Introdução

O desenvolvimento da bioeletrogênese cerebral do recém-nascido (NB) se manifesta por meio da permanente evolução e organização dos estados do ciclo de sono-vigília (Scher, 1998). As condições de saúde de recém-nascidos têm sido relacionadas ao percentual de tempo no qual estes permanecem nos estados de vigília (VIG), sono ativo (SA) e sono quieto (SQ), conforme apontado por Scher (1998). A permanência de um dos estados por mais de uma hora revela ser essencial uma análise minuciosa do NB na busca de possível disfunção neurológica (Vaadia *et al.*, 1989).

O conhecimento e a análise do ciclo sono-vigília tem grande valor prognóstico para o NB, sendo fundamental a distinção entre estados (Lombroso, 1993). Os altos índices de ocorrência de enfermidades e de morte em recém nascidos têm motivado o desenvolvimento de técnicas de prognóstico e diagnóstico das condições de saúde do NB, tais como a polissonografia (Nunes *et al.*, 1994). Assim, baseado na polissonografia (registro simultâneo do Eletroencefalograma - EEG, Eletromiograma - EMG, Eletroculograma - EOG, Eletrocardiograma - ECG - e ventilação) de a termos prematuros, Schramm *et al.* (2000) formularam a hipótese de prognóstico da síndrome da morte súbita em lactente.

O eletroencefalograma (EEG), do recém-nascido a termo normal, pode ser classificado em cinco estados (Nunes *et al.*, 1996). O estado I, associado ao SQ, caracteriza-se pela respiração regular, olhos fechados, nenhum movimento de cabeça ou membros, enquanto que no estado II, também com os olhos fechados, tem-se respiração irregular e pequenos movimentos corporais, sendo então associado ao SA. Por outro lado, no estado III, o NB encontra-se com os olhos abertos e em alerta, porém inativo, em contraposição ao estado IV (olhos abertos) quando apresenta movimentos bruscos, sem, entretanto, chorar. Finalmente, no estado V, com os olhos abertos ou fechados, o NB está agitado e chorando. Os estados III a V têm sido associados à VIG, mostrando EMG fásico e EEG-sem artefatos excessivos (Nunes *et al.*, 1996) e apresentando comumente os padrões de eletrográficos LVI (Low Voltage Irregular) e Misto.

Em SA (também denominado REM – *Rapid Eyes Movement*), ocorre também alterações do ritmo cardíaco e o EEG não apresenta padrões eletrográficos contínuos de baixa amplitude ou superposto com ondas lentas, semelhante aos padrões de VIG. Normalmente o Misto aparece após o período de VIG e, o LVI, logo após o período de SQ. No estado de SQ (não-

REM), o EEG apresenta dois padrões, HVS (*High Voltage Slow*) e TA (*Tracé Alternant*), sendo que este último, embora apresente ondas lentas de alta amplitude, também se caracteriza pela presença de transientes aleatórios rápidos de baixa amplitude, assemelhando-se à atividade LVI (Bosignoli e Infantosi, 2002). Logo após o nascimento a termo, o padrão TA prevalece no EEG, sendo que o padrão HVS aumenta progressivamente durante o estado SQ até se tornar predominante por volta da 4ª a 5ª semana com alguns breves períodos de TA, e então tende a desaparecer completamente (Lombroso, 1993, Nierdemeyer, 1998).

Sinais EEG multicanal têm sido utilizados na classificação do sono em diferentes estados (Galhanone *et al.*, 1996, Scher *et al.*, 1997, Grozinger *et al.*, 1997, e Shimada *et al.*, 2000). A complexidade na interpretação do EEG de recém-nascidos deve-se ao processo de desenvolvimento cortical, presença de artefatos nos sinais e do próprio conhecimento e experiência do especialista (Goel *et al.*, 1996). Assim, segundo Roberts e Tarassenko (1992), na classificação baseada somente no EEG, a concordância entre especialistas pode ser da ordem de 50%. Com vistas a aumentar a acuidade na classificação dos estados, a polissonografia com anotação simultânea das características dos diferentes sinais fisiológicos e das variáveis comportamentais (podendo haver também gravação em vídeo), têm sido empregada (Nunes *et al.*, 1996). Para tal, a padronização da análise e revisão dos princípios e procedimentos de registros dos sinais fisiológicos foi recentemente revista (Penzel e Contradt, 2000).

Metodologias de análise quantitativa e outras consideradas técnicas inteligentes têm sido empregadas na classificação de estados do ciclo sono-vigília de recém-nascidos. Galhanone *et al.* (1996) usaram a análise multivariada aplicada a parâmetros espectrais extraídos de trechos de 4 s de uma única derivação EEG e do EMG submentoniano de NB a termo, tendo obtido acurácia aproximadamente 65%. Scher *et al.* (1996) aplicaram esta mesma técnica a parâmetros extraídos, a cada minuto, de sinais de polissonografia de NB a termo e prematuro, obtendo acurácia de 93,3%.

Técnicas inteligentes baseadas em Redes Neurais Artificiais (RNA) têm sido empregadas na classificação de estados do sono, tais como os estudos com EEG de ratos (Coimbra *et al.*, 1994, Robert *et al.*, 1997), de humanos jovens ou adultos (Roberts e Tarassenko, 1992, Pfurtscheller *et al.*, 1992, Schaltenbrand *et al.*, 1993, Grozinger *et al.*, 1995, Grozinger *et al.*, 1997, Shimada *et al.*, 1998, 2000) e para maiores de seis meses (Baumgart-Schimitt *et al.*, 1998). Para esta faixa etária

em humanos, Dorffner (1997) aponta ser a RNA uma alternativa efetiva no reconhecimento de padrões de sono. Para tal, baseou-se em resultados de classificação do EEG por RNA com treinamento supervisionado baseado na técnica de retropropagação, sendo que a RNA por treinamento com aprendizado competitivo deveria ser utilizada em casos especiais.

Mais recentemente, Bosignoli e Infantosi (2002) obtiveram acurácia de 90 a 95% na classificação de SQ, SA e VIG de recém-nascidos a termo, ao utilizar parâmetros espectrais, extraídos trechos de sinais polissonográficos de 5 s de duração, como entrada de redes neurais de treinamento supervisionado. O presente artigo descreve o desenvolvimento de uma RNA treinada pelo aprendizado competitivo, denominada Mapa Auto-Organizável de Característica (MAOC), para o reconhecimento de padrões do ciclo sono-vigília de recém-nascidos a termo. A classificação pelo MAOC será comparada com a obtida com três RNA, uma para cada estado de sono, projetadas de modo independente e com aprendizado do tipo retropropagação (Bosignoli e Infantosi, 2002) para o mesmo conjunto de NB. Desta forma, espera-se contribuir para o estabelecimento de um sistema inteligente a ser empregado na monitorização de recém-nascidos internados em Unidades de Tratamento Intensivo Neonatal.

Aquisição e Pré-Processamento

Dez recém-nascidos a termo, normais, com até três dias de pós-parto, foram sujeitos deste estudo. Os exames foram realizados no período diurno, no Laboratório de Neurofisiologia Clínica do Instituto Fernandes Figueira (LNC/IFF), após amamentação da criança e durante sono espontâneo. Os recém-nascidos apresentavam peso de nascimento normal (2500-4000 g), índice de Apgar maior que sete (no primeiro e quinto minutos), e exame físico e neurológico também normais. Além destas informações, outros dados de interesse clínico, tais como data e hora de nascimento, motivo de internação, idade gestacional e concepcional (IC) e uso de medicação foram também anotados. A polissonografia foi realizada na presença de um membro do corpo clínico do Hospital após ter sido obtido o consentimento livre e esclarecido, fornecido por escrito pelos pais ou responsável e na presença de pelo menos um destes.

O protocolo de aquisição dos sinais EEG foi estabelecido em conjunto com especialistas médicos do LNC/IFF e tomando-se por base as recomendações da "AMERICAN EEG SOCIETY": nove eletrodos simetricamente posicionados em ambos os hemisférios sobre

escalpo (Figura 1) e adquiridas 12 derivações EEG bipolares (Fp2-C4, Fp1-C3, C4-O2, C3-O1, Fp2-T4, Fp1-T3, T4-O2, T3-O1, T4-C4, C4-Cz, Cz-C3, C3-T3). Os outros sinais fisiológicos adquiridos foram duas derivações EOG (Pg1-A1 e Pg2-A1), o EMG submentoniano (montagem bipolar) e a derivação D1 do ECG. O sinal de ventilação foi captado por meio de uma cinta abdominal usada em cinco dos recém nascidos (Tabela 1). Em geral, a duração do exame foi de no mínimo 60 minutos, podendo ser interrompido por solicitação dos pais ou por alteração das condições de saúde do recém-nascido, sendo em ficha apropriada anotado, por um especialista, o comportamento do NB a cada minuto.

Os sinais fisiológicos foram registrados em papel (polígrafo EEG-5414K, Nihon Kohden) e também armazenados em fita (gravador Teak de 22 canais, XR7000). A estes sinais aplicou-se filtragem passa-faixa (frequência de corte inferior de 0,5 Hz e superior de 35 ou 70 Hz), e realizou-se a amostragem em 256 Hz usando-se a placa A/D de 16 bits (DAQpad-




Figura 1: Protocolo de montagem dos eletrodos para aquisição do EEG de recém-nascidos. Região anatômica da localização dos eletrodos é indicada por letras (Fp: fronto polar; C: central; T: temporal; O: occipital), as quais são seguidas por números indicando o hemisfério esquerdo (ímpar) ou direito (par) ou pela letra z (linha média). A derivação EEG bipolar é indicada somente por números. **Figure 1:** Bipolar electrode montage for acquiring EEG from neonates. Anatomic region of the electrode is indicated by letters (Fp: front polar; C: central; T: temporal; O: occipital) which are followed by numbers indicating the hemisphere (odd: left, even: right hemisphere) or by the letter (z: midline). Bipolar EEG recording is designed only by numbers.

Tabela 1: Duração, em minutos, dos segmentos polissonográficos classificados como SA, SQ e VIG para cada recém-nascido e para o conjunto dos 10 recém-nascidos. (*) indica o recém-nascido para os quais se adquiriu também o sinal de ventilação. **Table 1:** Duration in minutes for the segments of the polysomnographic signals classified as SA, SQ and VIG for each neonate and for all neonates. (*) indicates the neonate from whom ventilation was also acquired.

Estado	1*	2*	3*	4*	5*	6	7	8	9	10	Total
VIG	10,4	—	14,6	5,0	1,6	—	—	—	5,2	1,6	38,4
SA	31,6	10,6	32,3	—	41,6	4,4	4,0	4,4	—	—	128,9
SQ	9,1	14,3	12,6	—	23,7	4,8	8,0	2,0	6,0	5,2	81,7
Total	51,1	24,9	59,5	5,0	66,9	9,2	12,0	6,4	11,2	6,8	249

MIO-16XE-50 de 16 canais - National Instruments) e um microcomputador portátil Pentium 133 MHz (Magitronic). Para os NB nos quais o sinal de ventilação foi amostrado, a derivação Fp2-C4 foi descartada. O software de aquisição, desenvolvido em LabView no Laboratório de Processamento de Sinais e Imagens do PEB/COPPE-LAPIS, permite a identificação automática e controle da A/D.

Os estados do ciclo sono-vigília foram classificados por meio de inspeção visual do registro em papel de todos os sinais fisiológicos, tendo o especialista considerado também as anotações comportamentais. Devido à variabilidade interindividual dos NB e ao próprio protocolo experimental adotado, a duração dos segmentos identificados como pertencentes a um determinado estado de sono varia consideravelmente entre os NB, podendo inclusive não ter sido possível identificar todos os estados em um mesmo NB (Tabela 1). A curta duração de VIG em alguns dos NB deveu-se, talvez, ao exame ter sido realizado após amamentação ou, conforme Carroll *et al.* (1999), a distribuição temporal dos estados serem dependente do estresse do parto. Para os estados SA e SQ (e.g., NB #4 e #10), a curta duração resultou da rejeição de trechos de sinal contaminados por artefatos. Para o conjunto dos NB (Tabela 1), a duração relativa dos estados do ciclo sono-vigília, 52% SA, 33% SQ e 15% VIG, é compatível com a distribuição temporal destes estados em NB normais, que é de 40-50% para SA e 35-40% para SQ (Scher, 1998).

Com base na classificação realizada (duração total de 4,2 h), calculou-se a Transformada Discreta de Fourier de trechos de 1 s de duração e, então, estimou-se (periodograma de Bartlett) a densidade espectral de potência de cinco trechos consecutivos de sinal (assumido estacionário, conforme Lopes da Silva, 1998), mantendo-se, assim, resolução em frequência de 1 Hz. O número de trechos de 5 s para cada estado de sono é mostrado na Tabela 2.

MAOC e sinais de ativação

A RNA com aprendizado não-supervisionado, segundo Haykin (2001), é um processo onde não se requer nenhum conhecimento *a priori* sobre o problema em estudo, não necessitando, portanto, de dados previamente categorizados. Neste aprendizado, os dados são organizados de modo a revelar as propriedades coletivas emergentes, ou seja, suas características de auto-organização (Simpson, 1992). Assim, utilizando-se regras de aprendizado competitivo (Grossberg, 1970 e 1982, Malsburg, 1973, Amari, 1983, Kohonen, 1997), tem-se um método automático de separação em classes para um dado conjunto de padrões. Quando a saída deste tipo de RNA é caracterizada pela formação de um mapa topográfico dos padrões de entrada, no qual a localização espacial (coordenadas dos neurônios de saída), correspondem a uma determinada característica intrínseca das entradas, tem-se o Mapa Auto Organizável de Característica, considerado inerentemente não-linear (Haykin, 2001).

O MAOC foi configurado de acordo com a topologia (Figura 2) desenvolvida por Kohonen (1997), que permite reconhecer e separar padrões com base no aprendizado competitivo entre os neurônios. A topologia adotada foi de N entradas e M saídas dispostas em uma grade bidimensional (5 x 5), sendo os

Tabela 2: Duração total em horas e número de segmentos de 5 s para os estados SA, SQ e VIG. (*) indica a duração total dos segmentos de polissonografia que incluem o sinal de ventilação. **Table 2:** Sleep estate distribution of 5 s data segments and total duration in hours for SA, SQ and VIG. (*) indicates this duration when the ventilation signal is included in the polysomnography.

	VIG	SA	SQ
3,4 h *	420	1.480	560
4,2 h	504	1.628	872

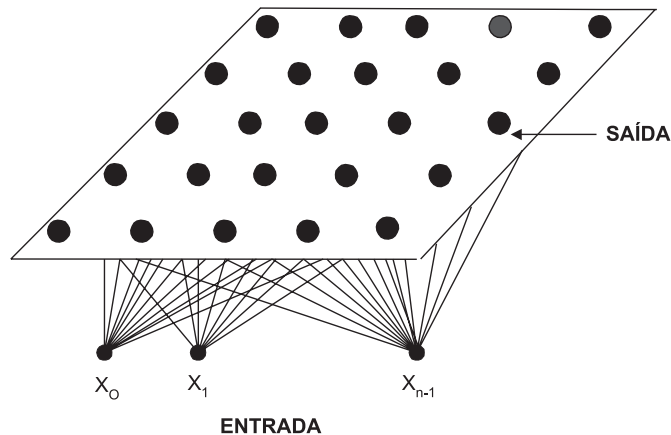


Figura 2: Conjunto de nós ($M=25$) de saída bi-dimensional usados para formar o mapa de Kohonen, tendo como entrada os vetores \mathbf{X}_i , onde $i = 0, 1, 2 \dots N-1$ (figura modificada de Lippmann, 1991). **Figure 2:** Two-dimensional array of M (25) output nodes used to build the feature maps of Kohonen, being the input the vectors \mathbf{X}_i , where $i = 0, 1, 2 \dots N-1$.

$M = 25$ neurônios de saída plenamente conectados às entradas. Inicialmente o MAOC foi projetado com dimensões 10×10 conforme proposto Roberts e Tarassenko (1992), reduzindo-se então para 5×5 com base no desempenho. Esta rede foi desenvolvida em Fortran 90 e implementada em um microcomputador PC K6-II 333 MHz.

O treinamento foi realizado em duas fases. Na primeira, determinaram-se o neurônio vencedor (maior saída) e os neurônios próximos, vizinhos topológicos (Simpson, 1992). Inicialmente, os vizinhos topológicos do neurônio vencedor eram todos os neurônios contidos em uma grade de 5×5 , centrada no neurônio vencedor, sendo então os pesos de cada uma das conexões desses neurônios ajustados. Na segunda, considerou-se somente o próprio neurônio vencedor e não mais sua vizinhança.

Os pesos das conexões entre cada um dos neurônios de saída e os neurônios de entrada foram inicializados de forma aleatória e normalizados. O produto interno foi então calculado e considerou-se como neurônio vencedor o de menor distância entre o vetor de entrada e o vetor de pesos. Os pesos das conexões desse neurônio e seus respectivos vizinhos topológicos foram a seguir modificados de modo a diminuir essa distância. A taxa de aprendizagem para correção dos pesos variou de 0,1 a 0,01, tendo-se adotado como regra para obtenção da convergência da rede o número de iterações mínimo de $500M$, conforme recomendado por Haykin, 2001 (Capítulo 9, p. 493).

Ao final do treinamento, os pesos foram considerados adaptados para especificar grupamentos asso-

ciados aos estados do ciclo sono-vigília. Sabendo que o NB permanece a maior parte do tempo em SA, seguido de SQ e, então, em VIG, considerou-se o maior grupamento da grade bidimensional como SA, o intermediário como SQ e o menor como VIG. A figura 3 ilustra a distinção entre as classes a partir de uma representação 3D, onde o eixo vertical refere-se ao número de vezes que um dado neurônio da grade é ativado, similarmente ao usado por Coimbra *et al.* (1994, 1995).

Entrada, Critérios de Classificação e Avaliação do MAOC

No desenvolvimento do primeiro MAOC considerou-se como entrada o parâmetro espectral de potência média relativa nas faixas de frequência características: delta (1-3 Hz), teta (4-7 Hz), alfa (8-13 Hz) e beta (14-25 Hz) para cada uma das derivações EEG. Para os demais sinais polissonográficos, ECG, EMG, EOG e Ventilação, foram também extraídas as potências médias relativas, porém em faixas de frequência características, conforme descrito em Bosignoli e Infantosi (2002). Para o EOG e a ventilação utilizaram-se as mesmas bandas estabelecidas para o EEG; sendo que, para a ventilação observou-se limite máximo de 10 Hz. Para o ECG, as faixas 1-4 Hz, 5-10 Hz e 11-35 Hz foram as utilizadas e para o EMG, as bandas 1-4 Hz, 5-8 Hz e 9-35 Hz. Assim, este MAOC foi projetado com 61 entradas.

O segundo MAOC foi projetado com 27 entradas obtidas a partir de procedimento de extração de características mais relevantes para a classificação (Tabela 3), conforme descrito em Bosignoli e Infantosi




Figura 3: Ilustração da resposta do MAOC (N=61), mostrando picos aos quais foram associados os estados do ciclo sono-vigília (SA, SQ, VIG). **Figure 3:** Illustration of SOM for N = 61, showing three clusters which can be associated to the sleep states SA, SQ and VIG.

(2002). Duas outras redes foram também projetadas; uma para separar somente os estados SQ e VIG usando estas 27 entradas; outra, com 16 entradas correspondentes aos parâmetros determinados na caracterização dos estados SQ e VIG (Tabela 3).

Por facilidade, designou-se vetor como o conjunto de parâmetros de potência extraídos dos sinais fisiológicos de 5 s de duração, resultando em 2.400 vetores (correspondendo a 3,4 h de exame). Para se fazer a validação cruzada das RNA, o conjunto de vetores foi separado aleatoriamente em três sub-conjuntos iguais, mantendo-se, porém, a proporcionalidade da classificação original (496 vetores classificados como SA, 184 vetores SQ e 120 VIG).

Na avaliação de desempenho, os índices de acurácia (AC), sensibilidade (S), especificidade (E) e valores preditivos positivo (VPP) e negativo (VPN) foram utilizados. A acurácia, tomada como índice global, definido por (Iatros, 2001):

$$AC = (VP+VN) / (VP+VN+FP+FN), \quad (1)$$

onde, VP (verdadeiro positivo) é o número de segmentos classificados corretamente, ou seja, por exemplo, segmentos SA de 5 s classificados corretamente pelo MAOC como sendo SA. Por outro lado, os segmentos SA classificados erroneamente como não pertencentes a esta classe constituem os falsos negativo (FN). O número de segmentos SQ ou VIG de 5 s classificados corretamente como não SA pelo MAOC é denotado por VN (verdadeiro negativo) e os segmen-

Tabela 3. Sinais fisiológicos para classificação dos estados do ciclo sono-vigília de SA, SQ e VIG, resultantes da redução da dimensionalidade por meio de uma RNA de treinamento supervisionado. (.) indica o número de parâmetros espectrais extraídos, totalizando N = 16 entradas da rede. **Table 3.** Physiological input signals for SOM extracted by ANN supervised learning. (.) indicates the number of spectral parameters extracted from a signal, resulting in N = 16 inputs.

Número de entradas	SA	VIG, SQ
N (16)	T4-Cz (4)	Cz-T3 (4)
	Fp2-O2 (4)	Fp1-O1 (4)
	EOG (3)	EOG (3)
	Vent. (2)	Vent. (2)
	EMG (3)	ECG (3)

tos SQ ou VIG classificados falsamente como SA pelo MAOC são os falsos positivo (FP). Considerando tais definições obtêm-se, então, os índices:

$$S = VP / (VP+FN) \quad (2)$$

$$E = VN / (VN+FP) \quad (3)$$

$$VPN = VN / (VN+FN) \quad (4)$$

$$VPP = VP / (VP+FP) \quad (5)$$

Resultados

O MAOC quando ativado com 61 parâmetros de entrada resultou em 77% de AC, tendo como pior índice de desempenho a S de SQ (25%), embora para VIG (79%) e SA (92%) a sensibilidade tenha sido bem mais elevada. Ao se reduzir o número de entradas do MAOC para 27, a AC diminuiu para 64% (Tabela 4), porém com S para SQ ainda baixa (37%); para os demais estados, a sensibilidade decai, tendo, entretanto, valores próximos a estes para VPP de VIG e SA.

Treinando-se o MAOC de 27 entradas somente com os estados VIG e SQ, a AC aumentou para 84% (Tabela 5), melhorando também os demais índices de desempenho. Uma maior acurácia (88%) obteve-se para o MAOC projetado com somente os 16 parâmetros relativos a estes dois estados, sendo os demais índices de desempenho próximos ao valor de AC (Tabela 6).

Comentários Finais

Durante o desenvolvimento das redes, três agrupamentos distintos foram observados na grade de saída

Tabela 4. Desempenho do MAOC com 27 entradas para classificação dos estados do ciclo sono-vigília de SA, SQ e VIG. S = sensibilidade, E = especificidade, VPP = valor preditivo positivo, VPN = valor preditivo negativo e AC = acurácia, todos em percentagem. **Table 4.** Performance of the SOM for 27 inputs classifying sleep-wake states of SA, SQ and VIG. S = sensitivity, E = specificity, VPP = positive predictive value, VPN = negative predictive value and AC = accuracy.

Estados	S	E	VPP	VPN	AC
VIG	43	91	44	91	-
SA	77	41	71	49	-
SQ	37	90	48	85	-
Total	-	-	-	-	64

Tabela 5. Desempenho do MAOC com 27 entradas para classificação de somente SQ e VIG. S = sensibilidade, E = especificidade, VPP = valor preditivo positivo, VPN = valor preditivo negativo e AC = acurácia, todos em percentagem. **Table 5.** Performance of the SOM for 27 inputs classifying only SQ and VIG. S = sensitivity, E = specificity, VPP = positive predictive value, VPN = negative predictive value and AC = accuracy.

Estados	S	E	VPP	VPN	AC
VIG	79	86	79	86	-
SQ	86	79	86	79	-
Total	-	-	-	-	84

Tabela 6. Desempenho do MAOC com 16 entradas para classificação de somente SQ e VIG. S = sensibilidade, E = especificidade, VPP = valor preditivo positivo, VPN = valor preditivo negativo e AC = acurácia, todos em percentagem. **Table 6.** Performance of the SOM for 16 inputs classifying only SQ and VIG. S = sensitivity, E = specificity, VPP = positive predictive value, VPN = negative predictive value and AC = accuracy.

Estados	S	E	VPP	VPN	AC
VIG	89	88	83	88	-
SQ	88	89	88	83	-
Total	-	-	-	-	88

do MAOC, aos quais foram associados os três estados do ciclo sono-vigília (VIG, SQ, SA) de recém-nascidos. Roberts e Tarassenko (1992) também associaram agrupamentos no MAOC a estados distintos do ciclo sono-vigília de humanos, porém de adultos e jovens. Tal associação é também relatada por Coimbra *et al.* (1994) em estudos com ratos.

Embora os MAOC desenvolvidos para classificação dos três estados em recém nascidos tenham acurácia ainda não adequada, variando de 64% a 77%, este desempenho é superior ao obtido por Dorffner *et al.* (1993) e Moreno *et al.* (1995). Utilizando esse mesmo tipo de rede, porém para humanos de outra faixa etária, Dorffner *et al.* (1993) na determinação da informação do mapa de coerência obteve AC = 60%, valor próximo (63%) do obtido por Moreno *et al.* (1995) em estudos de maturação.

Entretanto, Roberts e Tarassenko (1992) enfatizam a habilidade do MAOC em reconhecer estados do ciclo sono-vigília de adultos e jovens humanos. Por outro lado, Dorffner (1997), com base no projeto ANNDEE (*Enhancement of EEG-based diagnosis of neurological and psychiatric disorders using artificial neural networks*), comenta que, para humanos maiores de seis meses, esse tipo de rede não deve ser utilizado quando se conhece *a priori* a classificação; sugerindo o uso criterioso do MAOC, pois esta rede não resulta em melhoria do desempenho quando comparadas às técnicas tradicionais de agrupamento ou a RNA de treinamento supervisionado.

A acurácia dos MAOC é superior ou próxima dos 65% obtido por Galhanone *et al.* (1996), que aplicou análise multivariada ao EEG multicanal de NB (trechos de 4 s de duração). No entanto, os MAOC apresentam pior desempenho comparado aos resultados de Scher *et al.* (1996), AC de 90 a 97%, ao utilizar análise discriminante para trechos de 32 sinais fisiológicos (duração de 60 s) de NB. RNA de treinamento supervisionado (AC: 90-95%) também resultaram em desempenho superior (Bosignoli e Infantosi, 2002) ao dos MAOC. Moreno *et al.* (1995), comparando o MAOC a RNA de treinamento supervisionado, também obteve melhor desempenho para essa última rede.

A redução do número de estados a serem analisados pelo MAOC para 16 parâmetros espectrais de sinais fisiológicos de VIG e SQ implicou em aumento da AC para 88%, porém com desempenho ainda menor que o da RNA de treinamento supervisionado (Bosignoli e Infantosi, 2002), embora parâmetros depurados pela RNA de treinamento supervisionado para esses estados tenham sido utilizados como entrada.

Embora o desempenho do MAOC não seja superior ao da RNA de treinamento supervisionado, tal aspecto evidencia a confiabilidade da classificação realizada pelo especialista para o conjunto de sinais em estudo. A acurácia de 88% obtida com o MAOC é muito superior a concordância de 50% na classificação subjetiva realizada por especialistas com base somente no EEG, apontada por Roberts e Tarassenko (1992). Mesmo que se desconhecesse a classificação do especialista, como intrinsecamente assumido pelo MAOC, ainda assim três classes teriam sido identificadas. Embora a interpretação do EEG de recém-nascidos, devido a maturação cortical e a presença de artefatos, seja bastante complexa (Goel *et al.*, 1996), o desempenho do MAOC indica a possibilidade de se utilizar tal classificação, em particular no desenvolvimento de RNA de treinamento supervisionado.

O MAOC por ter característica de não necessitar de entradas rotuladas possui, inerentemente, a capacidade de estabelecer uma rotulagem por meio dos agrupamentos resultantes. Assim, o MAOC de 27 entradas indicou a presença das três classes enquanto o MAOC de 16 entradas apontou a existência de somente dois estados. Tais resultados e a comparação entre o desempenho do MAOC e os das RNA de treinamento supervisionado, sugerem o uso do MAOC em conjunto com estas redes, talvez utilizando a saída destas como grau de pertinência de classe.

Agradecimentos

Ao PRONEX/MCT, CNPq e FAPERJ pelo apoio financeiro, e aos Drs. Paulo Ricardo Galhanone e José Raphael Bokehi pelo auxílio na polissonografia neonatal.

Referências

Amari, S., 1983, "Field Theory of Self-organization Neural Nets", *IEEE Transactions on Systems, Man and Cybernetics*, v. 13, n. 6, p. 741-748.

Baumgart-Schmitt, R., Herrmann, W.M., Eilers, R., 1998, "On the Use of neural network techniques to analyze sleep EEG data. Third Communication: robustification of the classifier by applying an algorithm obtained from 9 different networks". *Journal of Neuropsychobiology*, v. 37, n. 1, p. 49-58.

Bosignoli, R., Infantosi, A.F.C., 2002, "Redes neurais artificiais na classificação de estados do ciclo sono-vigília em recém-nascidos", *Revista Brasileira de Engenharia Biomédica*, v. 18, n. 2, p. 113-125.

Carroll, D.A., Denenberg, V.H., Thoman, E.B., 1999, "A Comparative Study of Quiet Sleep, Active Sleep and Waking on the First 2 Days of Life", *Dev. Psychobiol.*, v. 35, n. 1, p. 43-48.

Coimbra, A.J.F., D'Angelo, G.G., Azevedo, F.M., Marino, J.N., Barreto, J.M., 1994, "Electrographic Analysis of Brain States Using Neural Networks. In: *World Congress on Medical Physics and Biomedical Engineering*, p. 463, Rio de Janeiro, August.

Coimbra, A.J.F., Marino, J.N., Azevedo, F.M., Freitas, C.G. e Barreto, J.M., 1995, "Brain Electrographic State Detection Using Combined Unsupervised and Supervised Neural Networks". In: *Artificial Neural Nets and Genetic Algorithms*, Eds.: D.W. Pearson, N.C. Steele e R.F. Albrecht, New York: Springer Verlag, p. 76-79.

Dorffner, G., 1997, "Can Neural Networks Improve Signal Processing? – A Critical Assessment from the ANNDEE Project", *Proceedings of Measurement 97*, Comunicado do Projeto ANNDEE, em Austrian Research Institute Artificial Intelligence [online] disponível no <http://www.ai.univie.ac.at/georg/papers/measurement.ps.Z/> [Acessado em 05/03/2001].

Dorffner, G., Rappelsberger, P., Flexer, A., 1993, "Using Self Organizing Feature Maps to Classify EEG Coherence Maps". In: *Proceedings of the ICANN/93*, p. 882-887, Heidelberg.

Galhanone, P.R., Infantosi, A.F.C., Simpson, D.M., 1996, "Classificação de Padrões Eletro-Encefalográficos das Fases de Sono-Vigília Neonatais", *Revista Brasileira de Engenharia, Caderno de Engenharia Biomédica*, v. 12, n. 3, p. 63-73.

Goel, V., Brambrink, A.M., Baykal, A., Koehler, R.C., 1996, "Dominant Frequency Analysis EEG Reveals Brain's Response During Injury and Recovery". *IEEE Transactions on Biomedical Engineering*, v. 43, n. 11, p. 1083-1092.

Grossberg, S., 1970, "Neural Pattern Discrimination", *J. Theoret. Biol.*, v. 27, n.4, p. 291-337.

Grossberg, S., 1982, *Studies of Mind and Brain: Neural Principles of Learning, Perception, Development, Cognition and Motor Control*, Boston: Rédel Press.

Grozinger, M., Rosche, J., Kloppel, B., 1995, "Automatic Recognition of Rapid Eye Movement (REM) Sleep by Artificial Neural Networks", *J. Sleep Res.*, European Sleep Research Society, v. 4, n. 1, p. 86-91, Fev.

Grozinger, M., Wolf, C., Uhl, T., Schaffner, C., Rosche, J., 1997, "Online Detection of REM Sleep Based on the Comprehensive Evaluation of Short Adjacent EEG Segments by Artificial Neural Networks", *Prog. Neuropsychopharmacol Biol. Psychiatry*, v. 21, n. 6, p. 951-963.

Haykin, S., 2001, *Redes Neurais, Princípios e Prática*, 2ª Edição, Porto Alegre: Bookman Companhia Editora, Brasil.

Iatros (2001), Estatística e Pesquisa Científica para Profissionais de Saúde, "Tutorial de Desempenho de Testes", Endereço Internet: <http://www.vademecum.com.br/iatros> em 09/05/01.

Kohonen, T., 1997, *The Self-Organizing Maps*. Ed. K.V. Helmut Lotsch, Berlin: Springer Verlag.

Lombroso, C.T., 1993, "Neonatal EEG Polygraphy in Normal and Abnormal Newborns". In: *Electroencephalography-Basic Principles, Clinical Applications and Related Fields*. Eds. E. Niedermeyer and F. Lopes da Silva, Baltimore: Williams&Wilkins, p. 803-875.

Lopes da Silva, F., 1998, "EEG Analysis: Theory and Practice". In: *Electroencephalography: Basic Principles*,

- Clinical Applications and Related Fields*, Eds: E. Niedermeyer e F. Lopes da Silva, Lippincott: Williams&Wilkins, p. 1135-1163.
- Malsburg, C., 1973, "Self-organization of Orientation Sensitive Cells in the Striate Cortex", *Kybernetik*, v. 14, n. 1, pp. 85-100.
- Moreno, L., Piñeiro, J.D., Sánchez, J.L., Mañas, S., Merino, J., Acosta, L., Hamilton, A., 1995, "Brain Maturation Estimation Using Neural Classifier", *IEEE Transactions on Biomedical Engineering*, v. 42, n. 4, p. 428-432, Apr.
- Niedermeyer, E., 1998, "Sleep and EEG". In: *Electroencephalography Basic Principles, Clinical Applications and Related Fields*, Eds.: E. Niedermeyer e F. Lopes da Silva, 4^o ed., Baltimore: Urban and Schwarzenberg, p. 174-188.
- Nunes, M.L., Costa, J.C., Godinho, C.C., Rodrigues, M.P.R., 1994, "Prognóstico de Recém-Nascidos com Convulsões: Aspectos Clínicos e Eletroencefalográficos", *Jornal da Liga de Epilepsia*, v. 7, n. 1, p. 27-30.
- Nunes, M.L., Da Costa, J.C., Roitman, I., Fernandes, R.M.F., 1996, "Guia Técnico para Execução de Registro Poligráfico e Eletroencefalograma no Período Neonatal". *Brazilian Journal of Epilepsy and Clinical Neurophysiology*, v. 2, n. 1, p. 27-42.
- Penzel, T., Contradt, R., 2000, "Computer Based Sleep Recordings and Analysis", *Sleep Medicine Reviews*, v. 4, n. 2, p. 131-148.
- Pfurtscheller, G., Flotzinger, D., Matuschik, K., 1992, "Sleep Classification in Infants Based on Artificial Neural Network", *Biomed. Tech.(Berl)*, v. 37, n. 6, p. 122-130.
- Robert, C., Guilpin, C., Limoge, A., 1997, "Comparison between Conventional and Neural Network Classifiers for Rat Sleep-Wake Stage Discrimination", *Neuropsychobiology*, v. 35, n. 4, p. 221-225.
- Roberts, S., Tarassenko, L., 1992, "Analysis of the sleep EEG using a multilayer network with spatial organisation", *IEE Proceedings-F*, v. 139, n. 6, p. 420-425, Dec.
- Schaltenbrand, N., Lengelle, R., Macher, P., 1993, "Neural Networks Model: Application to Automatic Analysis of Human Sleep", *Computers and Biomedical Research Journal*, v. 26, n. 2, p. 157-171, Apr.
- Schramm, D., Scheidt, B., Hubler, A., Frenzel, J., Holthausen, K., Breidbach, O., 2000, "Spectral Analysis of Electroencephalogram During Sleep-Related Apneas in Preterm and Term Born Infants in the First Weeks of Life", *Clinical Neurophysiology*, v. 111, n. 10, p. 1788-1791.
- Scher, M.S., 1998, "Electroencephalography of the Newborn: Normal and Abnormal Features". In: *Electroencephalography: Basic Principles, Clinical Applications and Related Fields*, Eds.: E. Niedermeyer e F. Lopes da Silva, Lippincott: Williams&Wilkins, p. 896-946.
- Scher, M.S., Steppe, D.A., Banks, D.L., 1997, "Computer Classification of State in Healthy Preterm Neonates", *Sleep*, v. 20, n. 2, p. 132-141, Feb.
- Scher, M.S., Steppe, D.A., Banks, D.L., 1996, "Prediction of Lower Developmental Performances of Healthy Neonates by Neonatal EEG-Sleep Measures", *Pediatric Neurology*, v. 14, n. 2, p. 137-144.
- Shimada, T., Shiina, T., Saito, Y., 1998, "Sleep Stage Diagnosis System with Neural Network Analysis". In *Proceedings-20th Annual International Conference-IEEE/EMBS*, Institute of Information Sciences and Electronics, University of Tsukuba, Research Institute for EEG Analysis, Oct. 29/Nov.1, Hong Kong, p. 2074-2077.
- Shimada, T., Shiina, T., Saito, Y., 2000, "Detection of Characteristics Waves of Sleep EEG by Neural Network Analysis", *IEEE Transactions on Biomedical Engineering*, v. 47, n. 3, p. 369-379.
- Simpson, P. K., 1992, "Foundations of Neural Networks". In: *Artificial Neural Networks, Paradigms, Applications and Hardware Implementations*, Eds.: Edgar Sánchez-Sinencio and Clifford Lau, New York: IEEE Press, p. 3-24.
- Stockard-Pope, J.E., Werner, S.S., Bickford, R.G., Curran, J.S., 1992, "Computer Techniques in Neonatal Electroencephalography". In: *Atlas of Neonatal Electroencephalography*, 2^o ed., New York: Raven Press, p. 369-380.
- Vaadia, E., Bergman, H., Abeles, M., 1989, "Neuronal Activities Related to Higher Brain Functions: Theoretical and Experimental Implications", *IEEE Trans. Biomed. Eng.*, v. 36, n. 1, p. 25-35, Jan.