

## Sistema para Identificação de Padrões do Sono com o auxílio de Redes Neurais Dinâmicas

Marco Aurélio Benedetti Rodrigues.<sup>1</sup>; Fernando Mendes de Azevedo<sup>1</sup>; José Marino Neto<sup>2</sup>

<sup>1</sup>Grupo de Pesquisas em Engenharia Biomédica - GPEB - Departamento de Engenharia Elétrica

<sup>2</sup>Laboratório de Neurofisiologia I - LNFI - Departamento de Ciências Fisiológicas

Universidade Federal de Santa Catarina - UFSC

Florianópolis - Santa Catarina - SC

[benedett@gpeb.ufsc.br](mailto:benedett@gpeb.ufsc.br), [azevedo@gpeb.ufsc.br](mailto:azevedo@gpeb.ufsc.br), [marino@ccb.ufsc.br](mailto:marino@ccb.ufsc.br)

### Abstract

*The present work aims to identify sleep patterns identifications through the application of Dynamic Artificial Neural Networks (DANN). This one is very important in the identification and classification of the sleep stages. The input patterns of the network was obtained of an EEG registration of a patient during the sleep. The group of training patterns for DANN was constituted of 5 spindles of the sleep and 5 K Complex and 5 slow waves rhythms, characteristic of the two sleep phase.*

*The results obtained in the sleep patterns identification with DANN were compared with the results obtained by a Static Artificial Neural Network (SANN), with the purpose of showing the superiority of DANN. These training patterns were previously classified by a specialist, which agreed with approximately 90% of the identified patterns.*

### 1. Introdução

Métodos matemáticos e estatísticos vêm sendo aplicados no pré-processamento de sinais e reconhecimento de padrões, porém o especialista humano ainda é uma das melhores opções para classificação de padrões. Um Especialista através da simples inspeção de registros de eletroencefalograma (EEG) é capaz de identificar e classificar padrões característicos de todas as fases do sono, determinar visualmente a frequência predominante em cada época do registro, bem como padrões característicos como fusos e complexos K.

O desejo de construir artefatos capazes de apresentarem algum tipo de comportamento inteligente, faz com que estruturas matemáticas ou programas matemáticos sejam desenvolvidos, visando a reprodução com detalhes suficientes das estruturas biológicas responsáveis pelos mecanismos da inteligência. A construção de Redes Neurais Artificiais (RNA) tem como inspiração o sistema nervoso e os neurônios biológicos, com a esperança da emergência de algum tipo de comportamento inteligente da rede [1][4].

Entretanto, é importante compreender que, atualmente, as RNA estão muito distantes das redes Neurais Naturais (RNN), devido ao alto grau de paralelismo existente na estrutura cerebral humana.

A diferentes atividades elétricas do cérebro, representadas nos registros de EEG durante o sono, foram primeiramente subdivididas em dois estágios por Loomis et al.[7]. Loomis dividiu o sono em apenas dois estágios, o estágio REM e Não REM (NEM). Atualmente os padrões para o estagamento do sono utilizam os critérios estabelecidos por Rechtschaffen e Kales [9]

Os padrões de entrada para as RNA localizam-se no sono NREM. O sono NREM se subdivide em quatro estágios com gradativa diminuição de estímulos externos, tonus muscular e atividades elétricas cerebrais distintas.

O estágio 2 é definido pela presença de fusos do sono, complexos K e a ausência de ondas lentas de alta voltagem suficientes para definir o estágio 3 e 4. O estágio 2 é um dos estágios mais importantes do sono NREM, pois representa cerca de 70% do tempo total do sono no homem.

A presença de fusos e complexos K no registro de EEG, caracteriza o estágio 2 do sono, porém, estes padrões podem aparecer esporadicamente no sono REM. A identificação destes padrões segue a seguinte regra: para fusos do sono é necessário uma atividade cerebral na faixa de 12 a 14 Hz com duração mínima de 0,5 segundos; já para o complexo K, o seu formato é o mais importante, o qual é constituído de uma parte negativa bem delineada imediatamente seguida por uma componente positiva e com duração de mínima de 0,5 segundos. O formato de fusos e complexos K pode variar na sua forma e amplitude, apresentando um grande problema para sua identificação[6]. Por esse motivo, neste trabalho tentamos identificar esses padrões através de RNA.

A aplicação das RNA especializadas na identificação de fusos e complexos K durante o sono é um problema complexo, pois os padrões variam muito de indivíduo para indivíduo [5]. O objetivo deste trabalho é o desenvolvimento de métodos e técnicas de análise para o

processamento de sinais de eletroencefalografia, bem como para os demais registros bioelétricos importantes na identificação das fases do sono. A utilização de RNAD possui a finalidade de auxiliar os especialistas na detecção e classificação de padrões, agilizar e tornar mais rápido o processo de classificação dos distúrbios do sono, os quais, demoram horas para serem realizados por um especialista da área [2][3].

Outro objetivo é apresentar a estrutura da Rede Neural Artificial Dinâmica (RNAD) especialista na identificação de fusos e complexos K durante o sono, mostrar os resultados da identificação destes padrões e comparar os resultados obtidos com os de uma Rede Neural Artificial Estática (RNAE). Esta comparação tem como finalidade verificar a capacidade das RNAE e RNAD de distinguir os padrões treinados entre os diversos tipos de sinais presentes nos registros de EEG durante o sono.

## 2. Material e Métodos

Os registros de EEG, bem como os demais registros eletrográficos, apresentam características e padrões que se modificam em um determinado intervalo de tempo. A maneira em que os sinais variam no tempo não caracteriza uma única função e, sim, um conjunto delas sobrepostas (sinais de varias frequências, artefatos, fusos, complexos K, etc..).

O sinal de EEG, captado no escalpo do paciente é constituído de uma combinação de frequências e amplitudes provenientes de diversos locais do cérebro. Alguns tipos de sinais de EEG podem ser função de estímulos externos ou mesmo estímulos internos do organismo, por exemplo, de determinados medicamentos. Pela definição de sistemas dinâmicos, o registro de EEG pode ser representando matematicamente como um sinal dinâmico, isto é, composto de variáveis funcionais e temporais [8]. A estrutura de um sistema dinâmico pode ser resumido conforme a Equação 1, onde o sinal S é função de um conjunto de variáveis.

$$S = \{T, U, \Omega, Y, \Gamma, X, \phi, \eta\}$$

Equação 1 – Representação de um sistema dinâmico S

Onde:

T representa o conjunto de tempo;

U o conjunto de valores de entrada;

$\Omega$  o conjunto de funções de entrada;

Y o conjunto de valores de saída;

$\Gamma$  o conjunto de funções de saída,

X o conjunto de estados;

$\phi$  a função de transição de estado:

$\phi = T * T * X * \Omega \rightarrow X$ ;

$\eta$  a função de saída  $\eta = T * X * U \rightarrow Y$

Devido as características dinâmicas do sinal de EEG, neste sistema proposto utilizamos uma RNAD especialista para cada tipo de padrão do sono, isto é, uma RNAD especialista no reconhecimento de fusos do

sono e outra especialista no reconhecimento de complexos K.

As RNAD propostas neste artigo, possuem, como entrada, uma camada constituída de 90 neurônios. A entrada de cada neurônio é interligada com a saída de uma malha de atraso. A camada intermediária da rede neural é composta de 40 neurônios, totalmente interconectados com os neurônios da camada de entrada. A camada de saída da rede neural é composta de apenas um neurônio interconectado em todos os neurônios da camada intermediária. A saída deste neurônio é interligada a outra malha de atraso com a finalidade de armazenar os elementos de saída durante a entrada dos padrões na rede.

A Figura 1 apresenta a estrutura do sistema, onde RNDA1 é rede especialista da identificação de Fusos e RNDA2 é a rede especialista na identificação de complexos K.

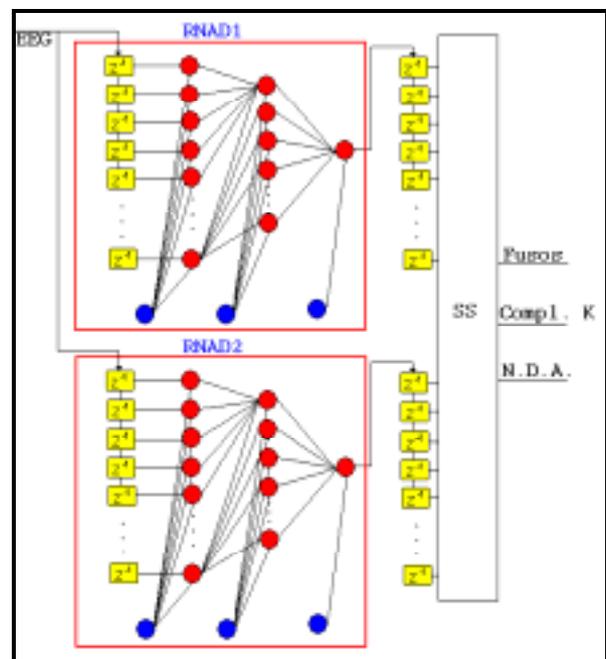


Figura 1 – Estrutura do Sistema Dinâmico

Nas RNAD cada neurônio possui um *bias* com a finalidade de aumentar ou diminuir o seu nível de ativação, auxiliando, desta forma, na etapa de treinamento [13]. O treinamento das RNAD foi realizado através de um algoritmo baseado no *backpropagation*, onde cada atualização dos pesos é realizada conforme a entrada de cada valor digitalizado do EEG, isto é, para cada valor de entrada, na malha de atraso, é realizado um treinamento na rede. No início do treinamento, antes de entrar o primeiro ponto do sinal para ser treinado, todas as saídas da malha de atraso apresentam o valor 1. Este valores se modificam a medida que os padrões de entrada começam a entrar pela malha de atraso.

O treinamento da rede foi realizado com um conjunto de registros de um paciente sem distúrbios do sono, cedidos por um especialista da área (Figura2). Os padrões de treinamento, como os complexos K e fusos

do sono também foram previamente selecionados por um especialista afim de tornar o aprendizado da rede o mais correto possível. Os vetores de entrada das Rede Neurais são compostos por segmentos dos registros de EEG, captados na derivação C3-RF. Estes registros foram amplificados, filtrados e digitalizados conforme os padrões utilizados pelo Sistema de Aquisição e Análise de Sinais BIOelétricos (SAASBIO III), desenvolvido no GPEB-UFSC [10][11][12].

Os vetores de entrada para as Redes Neurais foram parametrizados de tal forma que o valor máximo de amplitude correspondesse ao valor um, e o valor mínimo a zero. Isso é necessário devido à grande variação de amplitude que pode ocorrer de indivíduo para indivíduo e, até mesmo, entre tipos diferentes de eletrodos utilizados na captação dos sinais. Na identificação de complexos K e fusos do sono a amplitude não possui grande importância, mas sim a variação de amplitude que pode ocorrer durante um determinado padrão, bem como a frequência, formato, e duração destes [9]. Esta faixa fixa de valores de entrada na RNAD facilitou no treinamento e no posterior reconhecimento dos padrões do sono.

Em nosso experimento a rede foi treinada com 5 padrões de fusos, 5 complexos K e 5 padrões da fase dois do sono. Cada padrão é constituído de noventa pontos, o que representa uma duração de aproximadamente 1 segundo. Este tempo foi escolhido levando em consideração o tempo mínimo de duração de um fuso ou de um complexo K, o qual segundo Rechtschaffen & Kales [9] é de 0,5 segundos. O valor da janela de tempo escolhida é o dobro da duração mínima de um fuso ou complexo K devido a dois motivos principais: primeiro a existência de fusos e complexos K um pouco maiores que 0,5 segundos e, segundo a possibilidade do deslocamento do sinal no tempo através dos 90 neurônios da camada de entrada da rede, o que reflete significativamente no aprendizado e na identificação dos padrões.

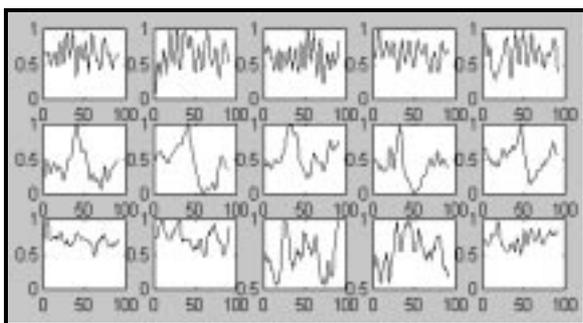


Figura 2 – Padrões de treinamento das RNAD

Na Figura 2, os cinco primeiros padrões de treinamento (parte superior da figura) são registros relativos à ocorrência de fusos no EEG durante o sono. Na parte central da Figura 2 aparece um conjunto de cinco complexos K e na parte inferior um conjunto de ritmos de ondas lentas. Este último padrão não possui nenhum tipo de característica definida, apenas

frequências e amplitudes características da fase 2 do sono.

A sequência dos padrões de treinamento das RNAD é um fator importante. A sua mudança de ordem pode ocasionar um maior ou menor tempo de treinamento, bem como, a possibilidade do aparecimento de mínimos locais. Na Tabela 1 é apresentada a ordem em que os padrões que foram apresentados à rede. Em nosso sistema foi adotada a forma sequencial de treinamento da RNAD, cada padrão é apresentado em sequência: um fuso, um complexo K e um ritmo de ondas lentas.

A atualização dos pesos da rede é realizada a cada ponto, de acordo com a entrada dos pontos pela malha de atraso. O padrão alvo para saída da rede (apresentado na tabela 1) somente é alterado após a rede ter realizado o treinamento com cada um dos 90 pontos de cada padrão de entrada. O treinamento das RNAD foi realizado até que o somatório do erro médio quadrático total (SEQT) fosse menor ou igual a 0.02, com uma taxa de aprendizado da rede (*learning rate*) igual a 0.01.

A malha de atraso localizada na saída das RNAD tem como finalidade o armazenamento de todos os valores de saída das duas RNAD em dois vetores. Esse vetor nós chamamos de Vetor de Saída da Rede Neural (VSRN) e é importante no treinamento e na verificação dos padrões identificados pela rede.

O critério de parada do treinamento da RNAD é realizado tomando como base a análise do VSRN. O erro das RNAD é calculado tomando como base a diferença do vetor de VSRN e um vetor de 1s, para ambas as RNAD. Sendo que, para RNDA1 o vetor de 1s é relacionado com o aparecimento de fusos do sono, e para a RNDA2 um vetor de 1s relativo ao aparecimento um complexo K do sono.

Tabela 1 – Padrões de Treinamento para as RNAD

Padrões de Entrada para as RNAD	Padrão de Saída para a RNDA1	Padrão de Saída para a RNDA2
1 a 5 – Tipos de Fusos	1	0
6 a 10 – Tipos de Complexos K	0	1
11 a 15 – Ritmo de Ondas lentas	0	0

Após o treinamento, estes dois vetores resultantes (VSRN) são, posteriormente, analisados por um sistema simbólico, afim de verificar se a rede conseguiu, ou não, detectar algum tipo de complexo K ou fuso do sono. O Sistema Simbólico (SS), representado na figura 1, tem como finalidade realizar uma classificação dos resultados da saída da rede neural, através da análise do comportamento dos dados de saída das RNAD de acordo com o tempo, isto é, verificar se a saída da rede neural apresentou um nível lógico 1 ou 0 (aproximadamente), durante um intervalo de tempo de 3 segundos. Essa análise deve ser realizada devido ao comportamento dinâmico dos dados de saída da rede, isto é, variantes no tempo.

Em nosso experimento, através da inspeção comparativa dos resultados dos VSRN de ambas RNAD com os resultados da classificação de um médico especialista, chegamos a um critério para classificação das saídas das RNAD. O critério de classificação foi escrito através de regras de produção e pode ser resumido conforme o Algoritmo 1. A análise realizada pelo SS, somente é realizada após a metade superior do VSRN, pois os primeiros valores dos vetor não são importantes e não apresentam um resultado consistente, devido ao fato da rede estar se adaptando dinamicamente ao sinal de entrada. Após, o SS realiza uma análise da metade superior dos VSRN, e a partir deste ponto procura um segmento de VSRN maior que 20 pontos, cujo o SEQT não ultrapasse o valor de 0,1. Essa situação representa uma saída válida e a identificação de algum tipo de padrão pela RNAD. Os vetor VSRN1 é relativo à RNDA1, isto é, responsável pela identificação de fusos do sono, e o VSRN2 relativo à RNAD2.

```

IF (VSRN > 50 %)
  THEN
    IF (  $\exists \overline{VSRN1} > 20 \text{ AND } SEQT(\overline{VSRM}) < 0.1$  ) THEN
      Padrão encontrado = Fuso do sono
      Fim da análise.
    END
    IF (  $\exists \overline{VSRN2} > 20 \text{ AND } SEQT(\overline{VSRN2}) < 0.1$  ) THEN
      Padrão encontrado = Complexo K
      Fim da análise.
    END
  END

```

Algoritmo 1 – Regras para o Sistema Simbólico

Com a finalidade de comparar os resultados na identificação de padrões pelas RNAD, foram projetadas duas Rede Neural Estáticas (RNAE), com a mesma topologia das RNAD, isto é, mesmo número de camadas, mesmo número de neurônios por camada, mesmo método de treinamento, algoritmo do tipo *backpropagation*, etc.

Porém, a RNAE não possui as malhas de atraso nem a dinâmica do sinal na entrada e na saída. O padrão é apresentado para rede por completo, isto é, os 90 elementos (pontos) simultaneamente. A saída da RNAE durante o treinamento é idêntica a das RNAD, os padrões de treinamento da rede são os mesmos da Figura 2 e seqüência de treinamento segue a mesma estrutura da Tabela 1.

As RNAE foram treinadas de maneira similar às RNAD, uma especializada na identificação de fusos e outra na identificação de complexos K. A estrutura básica das RNAE está ilustrada na Figura 3

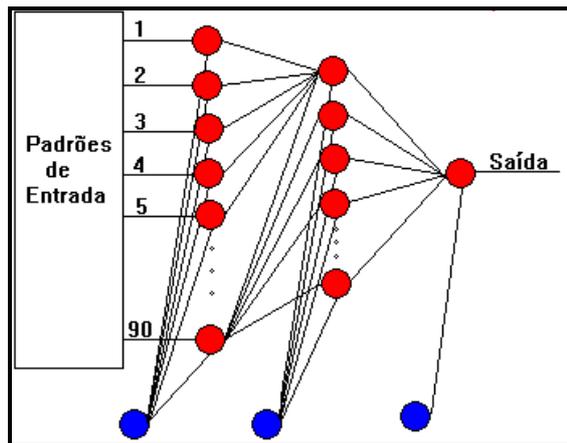


Figura 3 – Estrutura das RNAE

### 3. Resultados e Conclusões

Ambas as redes neurais, dinâmica e estática, foram treinadas até atingirem um valor do SEQT menor do que 0.02. Após o treinamento, a capacidade das redes neurais em indentificarem padrões do sono foi testada com diversos padrões de entrada.

Primeiramente, foi testada a capacidade das redes no reconhecimento de fusos do sono. Na figura 4, à esquerda, é apresentado alguns padrões identificados pela RNAD1 como fusos do sono. Estes padrões não fazem parte do conjunto de treinamento da rede e são parte de um conjunto de 100 utilizados para validação das RNAD. A direita, a figura mostra o VSRN1 resultante do treinamento.

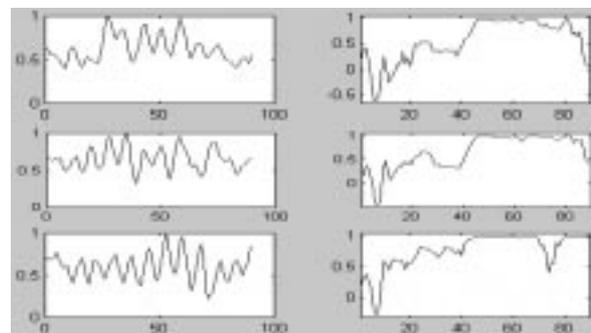


Figura 4 –Conjunto de Fusos e VSRN1 da RNAD1

O VSRN1 obtido com o resultado dos padrões de saída da RNAD1 foi analisado pelo SS. Os resultados obtidos classificaram todos os padrões de entrada da RNAD1 como sendo de fusos do sono.

O mesmo teste foi realizado com as RNAE1, porém obteve-se um resultado diferente. Somente um, o padrão 3, correspondente ao padrão mais inferior da Figura 4, foi identificado com sendo de um fuso do sono. A Tabela 2 mostra o valores de saída da RNAE1, onde um valor 1 corresponde a máxima ativação do neurônio de saída na identificação de um fuso.

Tabela 2 – Resultados da classificação da RNAE1

Padrão de entrada	Padrão de Saída
Padrão Número 1	0,3
Padrão Número 2	0,48
Padrão Número 3	0,98

Como um segundo teste, foi verificada a capacidade das redes no reconhecimento de complexos K do sono. A figura 2 apresenta alguns dos padrões identificados como complexo K pela RNAD2.

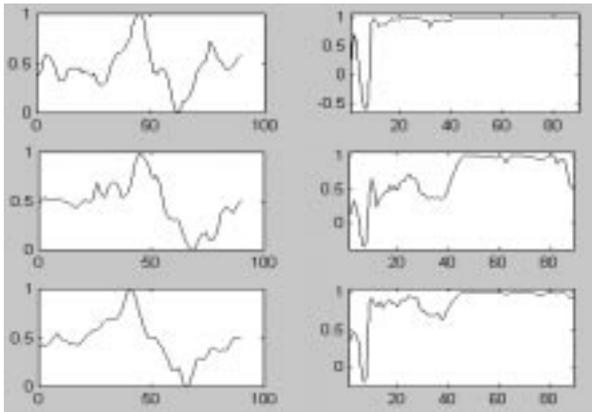


Figura 5 – Conjuntos de Complexos K e VSRN2 da RNAD2

Novamente, a RNAD1 através do SS conseguiu identificar todos os padrões como complexos K. Os resultados na identificação pela RNAE2 foram um pouco melhores neste teste, a RNAE2 conseguiu identificar como complexos K os padrões 1 e 3 da Figura 5.

Um terceiro teste foi realizado, desta vez com a finalidade de verificar a identificação de falsos positivos pelas redes neurais. Os padrões apresentados na Figura 6 são de ritmos de ondas lentas, ritmos característicos da fase 2 do sono, portanto o resultado na saída dos dois tipos de redes neurais deverá ser zero, isto é, não apresenta características de fuso nem complexos K.

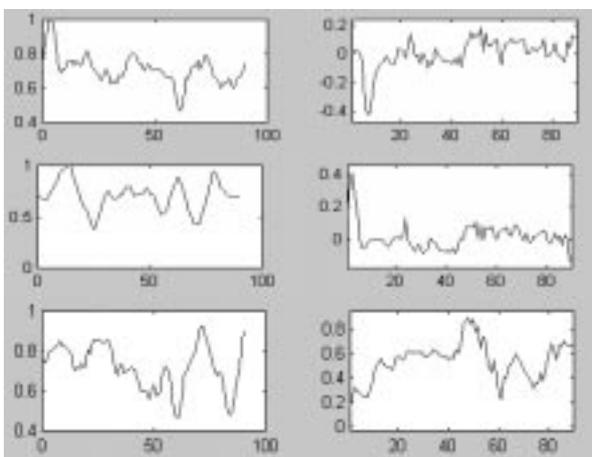


Figura 6 – Conjunto de ritmos de ondas lentas e VSRN das RNAD

Neste último conjunto de padrões para identificação, tanto a RNAD quanto a RNAE, apresentaram resultados semelhantes sem o aparecimento de falsos positivos. Isto ocorreu devido ao treinamento das RNAD e RNAE com um ritmo de ondas lentas. Este foi necessário devido ao grande número de falsos positivos que ocorrem durante o processo de identificação de padrões em ambos os tipos de redes.

Os conjuntos de testes apresentados acima servem como referência para análise e comparação do comportamento da RNAE e RNAD na identificação de padrões do sono. Tornou-se, ainda, necessário um teste final, a análise de um registro completo de EEG através da RNAD e outro análise através da RNAE. As redes neurais analisaram um registro de EEG de um paciente sem arritmias no EEG, durante um período de sono com 8 horas. Um especialista da área concordou com cerca de 90% dos complexos K e fusos do sono encontrados pela RNAD e 95% para os padrões da RNAE. Porém, na concepção do especialista a RNAD errou em identificar cerca de 20%, isto é, a RNAD deixou de identificar ou identificou erroneamente os padrões. Já relativo a RNAE, segundo o especialista, errou cerca de 50% dos padrões.

Embora número de falsos positivos na RNAE fosse menor que o obtido pela RNAD, ela apresentou um número muito menor de padrões reconhecidos. A RNAE identificou somente os padrões que se assemelhavam com os padrões treinados, não classificando muitos padrões que a RNAD identificou.

Concluimos, deste modo que o reconhecimento de padrões através de RNA estáticas não apresenta bons resultados, a utilização de redes neurais artificiais dinâmicas são mais indicadas neste tipo de processamento devido a dinâmica do sinal de EEG.

Convém levar em consideração que até mesmo o especialista teve dificuldades na classificação de alguns padrões que ele classificou. O especialista ao rever o mesmo exame em um outro dia, teve algumas divergências com as suas próprias classificações anteriores. Portanto, a utilização de RNAD, neste caso da detecção de padrões do sono pode ser bem aplicada, pois trata-se de um campo onde existe muita variação no “certo” e no “errado” para identificação de padrões do sono.

A rede neural proposta neste artigo faz parte de um sistema completo para identificação das fases do sono e de apnéias do sono que vem sendo realizado pelo GPEB-UFSC. Portanto, testes de sensibilidade e especificidade ainda estão sendo realizados com as RNAD e também com o especialista médico, afim de levantar dados para o refinamento final das RNAD.

### Referencias Bibliográficas

[1]Coimbra, A. J. F.; D'Angelo G. G.; de Azevedo, F.M.; Neto, J. M. & Barreto, J. M. "Electrographic Analysis of Brain States Using Neural Networks". World Congress on Medical Physics and Biomedical

- Engineering, Rio de Janeiro, 21-26 August 1994, Proceedings, Part I, Abstract PS17-1.11, pp: 463.
- [2]Coimbra, A. J. F.; Neto, J. M.; Freitas, C. G.; de Azevedo, F. M. & Barreto, J. M. "Automatic Detection of Sleep-Waking States Using Kohonen Neural Networks". I Congresso Brasileiro de Redes Neurais, Itajubá, MG, 24-27 Outubro 1994, Anais pp: 327-331.
- [3]Coimbra, A. J. F.; Neto, J. M.; de Azevedo, F. M.; Freitas, C. G. & Barreto, J. M. "Brain Electrographic State Detection Using Combined Unsupervised and Supervised Neural Networks". In: Artificial Neural Nets and Genetic Algorithms, Springer Verlag, D. W. Pearson & N. C. Steele & R. F. Albrecht (Eds), 1995, pp: 76-79.
- [4]de Azevedo, F. M. "Uma Proposta de Modelos Formais de Neurônios e Redes Neurais Artificiais". III Congresso Brasileiro de Redes Neurais, Florianópolis, SC, 20-24 Julho 1997, Anais: pp. 503-514. Trabalho convidado.
- [5]Dement W.C., "The Nature and function of sleep", *In* Reynolds D, Sjöberg A (eds.), Neuroelectric Research, Electroneuroprosthesis, Electroanesthesia, and Nonconclusive Electrotherapy. Springfield, IL, Charles C Tomas, 1970.
- [6]Gailard J.M., Blois R., "Spindle density in sleep of normal subjects. *Sleep* 4:385-391, 1981.
- [7]Loomis A.L., Harvey E.N, Hobart G.A., "Electrical potentials of the human brain", *J. Exp. Psychol*, 19:249-279, 1936.
- [8]Narendra, Kumpati S. & Parthasarathy, Kannan, "Identification and Control of Dynamical System Using Neural Networks", *IEEE Transaction on Neural Networks*, vol.1, no. 1, March, 1990.
- [9]Rechtschaffen, A., Kales, A."A manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects", Brain Information Service, Brain Research Institute, UCLA, Los Angeles, 1968.
- [10]Rodrigues, Marco Aurélio B.; de Azevedo, Fernando Mendes & Neto, J. M. "Instrumento Virtual para Aquisição de Sinais Bioelétricos". XV Congresso Brasileiro de Engenharia Biomédica - Forum Nacional de Ciência e Tecnologia em Saúde, 13-17 Outubro, Campos do Jordão, SP, 1996, Anais, Vol. I, pp: 257-258.
- [11]Rodrigues, Marco Aurélio B.; Toazza, Adriano L.; Silva, M. R.; de Azevedo, F. M. & Neto, J. M.. "Sistema de Aquisição e Análise de Sinais Bioelétricos III". I Congresso Latinoamericano de Ingeniería Biomédica, 11-14 Noviembre, 1998, Mazatlán, Mexico, Anales pp: 226-229.
- [12]Rodrigues, Marco Aurélio B. & Toazza, Adriano L.; Silva, M. R.; de Azevedo, F. M. & Neto, J. M. "Módulos de Expansão do SAASBIO III". I Congresso Latinoamericano de Ingeniería Biomédica, 11-14 Noviembre, 1998, Mazatlán, Mexico, Anales pp: 520-523.
- [13]Oliveira, Roberto C. L.; de Azevedo, F. M. & Barreto, J. M. "Dynamic Neural Net in the Space of States Utilized in Non-Linear Processes Identification". ICANNGA'97 - 3rd. International Conference on Artificial Neural Networks and Genetic Algorithms, Norwich, UK, April 1-4, 1997, Proceedings pp: 588-591.