

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E SISTEMAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**ESTAGIAMENTO AUTOMÁTICO DO SONO UTILIZANDO
UM CANAL DE EEG E UMA REDE NEURAL ARTIFICIAL
COM ALTA REPRESENTAÇÃO CORTICAL**

Tese submetida à Universidade Federal de Santa Catarina para a obtenção
do título de Doutor em Engenharia de Produção

MALCON ANDERSON TAFNER

**FLORIANÓPOLIS
AGOSTO / 1999**

MALCON ANDERSON TAFNER

**ESTAGIAMENTO AUTOMÁTICO DO SONO UTILIZANDO
UM CANAL DE EEG E UMA REDE NEURAL ARTIFICIAL
COM ALTA REPRESENTAÇÃO CORTICAL**

Esta tese foi julgada adequada para a obtenção do título de DOUTOR EM ENGENHARIA DE PRODUÇÃO e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia de Produção.

Prof. Ricardo Miranda Barcia, Ph.D.
Coordenador do Curso

BANCA EXAMINADORA:

PROF. RICARDO MIRANDA BARCIA, PHD
ORIENTADOR

PROF^a. EDIS MAFRA LAPOLLI, DR^a.

PROF. JOÃO BOSCO M. DA S. ALVES, DR.
CO-ORIENTADOR

PROF. ROBERTO C. S. PACHECO, DR.

PROF. MARCO A. B. CÂNDIDO, DR.

PROF. VINÍCIUS MEDINA KERN, DR.

Florianópolis, 16 de Setembro de 1999

***“Sonhar permite que cada um
e todos nós sejamos loucos,
silenciosamente e com segurança,
cada noite de nossas vidas.”***

***William C. Dement
Pesquisador de Sono e Sonhos***

À July

AGRADECIMENTOS

Foram muitas as pessoas que participaram, direta, ou indiretamente, na conclusão deste trabalho. Entre elas, gostaria de citar :

Ao meu orientador e amigo Professor Ricardo Miranda Barcia, cujos conhecimentos sempre transcenderam a academia.

À Professora Edis, cuja “força” e “maturidade” serão exemplos para muitas vidas à frente. Ao Professor Bosco, que na sua irreverência sempre soube impulsionar a ousadia e a auto-estima de todos. Ao Professor Roberto Pacheco, cujas críticas e idéias foram muito valiosas.

Gostaria de agradecer também a empresa EMSA, em nome de Bruno e Paulo, que tanto ajudaram fornecendo informações técnicas e registros polissonográficos para este projeto.

Agradeço também a CAPES pela bolsa que patrocinou grande parte desse trabalho, e a Universidade Federal de Santa Catarina, que através do Programa de Pós-Graduação em Engenharia de Produção me recebeu para a realização do mesmo.

Não poderia esquecer a nossa secretária da Engenharia de Produção, Neiva Gasparotti, que quebrou tantos “galhos” burocráticos quanto possível. Essa força, por mais pequena que pareça, de fato não o é !

Agradeço também aos examinadores externos da banca, que aceitaram o convite para esta defesa, engrandecendo o momento e a Engenharia de Produção da UFSC.

Aos novos e grandes amigos *JOÃO ARTUR, GERTRUDES E ROBERTO RAITTZ*, cujas madrugadas a dentro proporcionaram um espírito de equipe que poucas vezes conheci. Eis um grupo em que deposito minha total confiança e minhas mais sinceras gratidões...

Finalmente, à Julianne Fischer, quem certamente soube esperar e aturar, em todos os momentos a frase “tenho que acabar a minha tese”. Como ela, ninguém mais sabe tanto o que esta frase “verdadeiramente” significou !

Obrigado ...

SUMÁRIO

LISTA DE FIGURAS	VIII
LISTA DE TABELAS.....	IX
RESUMO	X
ABSTRACT	XI
1 INTRODUÇÃO.....	1
1.1 APRESENTAÇÃO DO TEMA E JUSTIFICATIVA	1
1.2 QUESTÕES ESPECÍFICAS	3
1.3 OBJETIVOS DA PESQUISA	3
1.3.1 <i>Objetivo Geral</i>	3
1.3.2 <i>Objetivos Específicos</i>	3
1.4 ORGANIZAÇÃO DO TRABALHO.....	4
2 FUNDAMENTAÇÃO TEÓRICA	5
2.1 O SONO E SUA ESTRUTURA.....	5
2.1.1 <i>O Sono</i>	5
2.1.2 <i>A Monitorização</i>	6
2.1.3 <i>O Procedimento para o Estagiamento do Sono</i>	9
2.1.4 <i>Progresso do Sono Durante a Noite</i>	14
2.1.5 <i>Generalidades sobre o sono normal</i>	16
2.1.6 <i>Características do sono REM</i>	17
2.1.7 <i>Os Distúrbios do Sono</i>	17
2.1.8 <i>Estagiadores do Sono</i>	19
2.2 REDE NEURAL ARTIFICIAL	24
2.2.1 <i>Breve História</i>	24
2.2.2 <i>Ciclo de Vida de uma Rede Neural</i>	24
2.2.3 <i>Estrutura da Rede Neural Artificial</i>	25
2.2.4 <i>O Neurónio Artificial (Micro-Estrutura)</i>	25
2.2.5 <i>Arquitetura e Dinâmica das Redes Neurais (Meso-Estrutura)</i>	28
2.2.6 <i>Paradigma de Aprendizado</i>	32
2.2.7 <i>Modelagem das Redes Neurais (Macro-Estrutura)</i>	32
2.2.8 <i>Aplicação das Redes Neurais</i>	32
2.2.9 <i>Porque Usar Redes Neurais Artificiais</i>	33
3 A REDE NEURAL ARTIFICIAL NO ESTAGIAMENTO AUTOMÁTICO DO SONO.....	34
3.1 INTRODUÇÃO	34
3.2 O PRÉ-PROCESSAMENTO	35
3.2.1 <i>O Sinal do EEG</i>	35
3.2.2 <i>Corte do Sinal Digital</i>	35
3.2.3 <i>Geração dos Índices Recursivos</i>	36
3.2.4 <i>Extração das Características</i>	37
3.3 REDE NEURAL ARTIFICIAL COM ALTA REPRESENTAÇÃO CORTICAL – ARC	38
3.3.1 <i>Arquitetura</i>	38
3.3.2 <i>Características</i>	39

3.3.3	<i>Alta Representação Cortical – ARC</i>	39
3.3.4	<i>A Conectividade da Rede Neural</i>	40
3.3.5	<i>O neurônio</i>	41
3.3.6	<i>Dinâmica do Aprendizado</i>	44
3.3.7	<i>Ajuste Sináptico da Vizinhança</i>	45
3.4	SOFTWARE DESENVOLVIDO.....	48
3.4.1	<i>Plataforma e Ambiente de Desenvolvimento</i>	48
3.4.2	<i>Um Pouco Sobre os Objetos</i>	48
3.4.3	<i>O Protótipo IndexArc</i>	49
4	A APLICAÇÃO	53
4.1	CONSIDERAÇÕES INICIAIS.....	53
4.2	TRATAMENTO DOS DADOS COLETADOS.....	53
4.3	TREINAMENTO DA REDE NEURAL.....	54
4.4	RESULTADOS OBTIDOS.....	54
4.4.1	<i>Testes com Treinamento do Paciente 6501</i>	54
4.4.2	<i>Testes com Treinamento do Paciente 6740</i>	57
4.4.3	<i>Análise dos Resultados</i>	58
5	CONCLUSÕES E RECOMENDAÇÕES	59
5.1	CONCLUSÕES.....	59
5.2	RECOMENDAÇÕES.....	60
6	REFERÊNCIAS BIBLIOGRÁFICAS	61

LISTA DE FIGURAS

Figura 1 – Diagrama dos principais registros da polissonografia (GUIOT, 1996)	6
Figura 2 - Diagrama esquemático dos eletrodos para a tomada do EEG (CARSKADON e RECHTSCHAFFEN, 1994).	7
Figura 3 – EEG enquanto acordado.....	10
Figura 4 – EEG em estágio 1	11
Figura 5 – EEG em estágio 2.....	11
Figura 6 – EEG em estágio 3.....	12
Figura 7 – EEG em estágio 4.....	12
Figura 8 – EEG em estado REM	13
Figura 9 - Exemplo de hipnograma	16
Figura 10 – Coletores de Sinal Eletrofisiológico	22
Figura 11 - Ciclo de vida de uma Rede Neural (TAFNER, 1995).	25
Figura 12 - Neurônio Artificial.....	26
Figura 13 – Potencial de ação mediante a despolarização celular.....	27
Figura 14 - Funções de transferências conhecidas (TAFNER, 1995).....	27
Figura 15 - Rede neural com simples camada de neurônios	28
Figura 16 - Rede neural com duas camadas de neurônios.....	28
Figura 17 - Rede neural com retroalimentação	29
Figura 18 - Rede neural com duas dimensões Lattice, 3 x 3 neurônios	29
Figura 19 – Trecho do sinal biológico original com os limites superior e inferior	35
Figura 20 – Vetor de índices	36
Figura 21 – Definição dos Intervalos da Partição	37
Figura 22 – Faixa de amplitudes e elemento de partição para o vetor de índices	37
Figura 23 – Todas as entradas estão conectadas com as saídas (neurônios).....	38
Figura 24 – Disposição de representações em um córtex artificial	40
Figura 25 – Neurônio artificial da rede neural ARC	41
Figura 26 – Atividade repetitiva perante a despolarização prolongada.....	42
Figura 27 – Força do Potencial de Ação do neurônio j	43
Figura 28 – Exemplo de raio para vizinhança igual a 2	46
Figura 29 – Estrutura Todo-Parte dos objetos do IndexArc.....	48
Figura 30 – Troca de mensagens durante o treinamento	49
Figura 31 - Troca de mensagens durante o reconhecimento	49
Figura 32 – Painel de conversão de arquivos	50
Figura 33 - Painel de operações.....	51
Figura 34 - Painel de resultados	52
Figura 35 – Distribuição dos Neurônios Treinados por Classe.....	55
Figura 36 – Hipnograma do paciente 7706	56

LISTA DE TABELAS

Tabela 1 – Classificação das frequências cerebrais.....	7
Tabela 2 – Regras para o Estagiamento do Sono	13
Tabela 3 – Classificação Internacional dos Distúrbios do Sono	18
Tabela 4 – Pacientes usados para o trabalho	53
Tabela 5 – Distribuição do Acerto para o Paciente 7706	55
Tabela 6 – Distribuição do Acerto para os Pacientes 6740 e 9300	57
Tabela 7 – Distribuição do Acerto para o Paciente 7706	57
Tabela 8 – Distribuição do Acerto para os Pacientes 6501 e 9300	58

RESUMO

O presente trabalho descreve aspectos preliminares para a implementação de um sistema de estagiamento automático das fases do sono utilizando apenas um sinal do eletroencefalograma, o canal C3. Para tanto, o trabalho procura descrever os principais aspectos relativos ao sono humano, como também os critérios adotados para o estagiamento manual pela eletroencefalografia.

O sistema proposto realiza um pré-estagiamento automático utilizando tecnologia de inteligência artificial, especificamente, redes neurais artificiais. O trabalho também realça a necessidade de se realizar um pré-processamento, combinando diferentes técnicas tais como, a indexação recursiva e a extração de características na tentativa de purificar o sinal original provindo do canal eletroencefalográfico.

ABSTRACT

The present work describes some preliminary aspects for the implementation of a system of sleep automatic staging using only one signal of the electroencephalogram, the channel C3. For that, the work tries not only to describe the main aspects related to the human sleeping, but also to present some criteria adopted for the manual staging by the electroencephalography.

The proposed system realizes an automatic pre-staging using artificial intelligence technology, specifically, artificial neural networks. The work also emphasizes the need of a preprocessing, matching different techniques such as the recursive indexation and the extraction of characteristics trying to clear the original sign that comes from the electroencephalographic channel.

1 Introdução

1.1 Apresentação do Tema e Justificativa

Os conhecimentos sobre o ciclo vigília-sono desenvolveram-se a partir da década de 30, quando Loomis e colaboradores (apud GUIOT, 1996), utilizando a eletroencefalografia, descreveram o sono como um processo unitário e passivo, composto por estágios, cada um com características próprias. Esse conceito do sono unitário perdurou até a década de 50, quando Aserink e Kleitman (apud GUIOT, 1996) observaram a existência de um outro estado de sono caracterizado por ativação cortical e surtos de movimentos oculares rápidos. A partir desse estudo o sono passa a ser considerado como um processo composto por dois estados biológicos distintos. Nos anos seguintes, novas pesquisas de Dement e Kleitman (apud GUIOT, 1996) verificaram que neste processo dual os dois estados de sono alternam-se ciclicamente, além de associar os sonhos com os movimentos oculares rápidos.

Atualmente, o sono não é mais considerado um fenômeno passivo, muito menos um período de repouso ao sistema muscular, órgãos viscerais, sistema nervoso, e outros. Não é possível dizer exatamente qual é a função que cumpre o sono, mas sabe-se, no entanto, que todas as funções do cérebro e do organismo em geral estão influenciadas pela alternância da vigília com o sono (VELLUTI, 1996). O sono é estudado como um fenômeno ativo, visto que não se observa uma redução generalizada da descarga dos neurônios cerebrais, mas um aumento de forma notável das frequências de descarga dos neurônios, chegando, inclusive, a níveis maiores do que os observados em vigília tranqüila.

Com a abertura de um novo campo da fisiologia, o estudo do sono, e a possibilidade de registro de um número considerável de variáveis durante o sono, o volume de pesquisas sobre o assunto cresceu significativamente. Em 1968 foram definidos os critérios de monitorização e estagiamento do sono por RECHTSCHAFFEN

e KALES. Apesar de revisado por CARSKADON e RECHTSCHAFFEN em 1994, o padrão de 68 ainda é adotado.

Através dos critérios de monitoração e estagiamento do sono é possível quantificar o sono efetivamente dormido. Esses critérios permitem também que sejam quantificadas as insônias e outros distúrbios que fragmentam o sono. Esses distúrbios, bem como outros problemas relacionados com a ausência do sono, têm um impacto profundo na estrutura e na distribuição do sono. Os sintomas podem ser diversos e complexos, sendo que os mais freqüentes sempre são a insônia durante a noite, e a sonolência excessiva durante o dia (VELLUTI, 1996). Assim, a quantificação desses dados é de extrema importância, pois através dessa estatística é possível identificar a qualidade do sono do paciente.

Seguindo os critérios de estagiamento, grande parte dos médicos e técnicos em polissonografia têm realizado o estagiamento do registro polissonográfico manualmente desde a década de 70. Essa tarefa, quando executada manualmente, é considerada tediosa, pois o registro de uma noite inteira de sono consome, aproximadamente, 3 horas de anotações e cuidadosa observação. Por esse tipo de motivo, muito esforço tem sido gasto em projetar estagiadores automáticos de sono.

Na tentativa de classificar o sono automaticamente nos diferentes estágios, segundo os critérios definidos por RECHTSCHAFFEN e KALES (1968), diversas técnicas tem sido adotadas desde a década de 70. Como exemplo, entre as propostas de sistemas automáticos que realizassem a tarefa da classificação, podemos citar: sistemas especialistas (RAY, LEE e MORGAN, 1986), análise multidimensional (BURGER, CANTANI e WEST, 1977), sistemas híbridos (GAILLARD e TISSOT, 1973) e, mais recentemente, redes neurais (PRINCIPE e TOME, 1989).

Atualmente, parte das pesquisas em estagiamento automático do sono tem tomado direção às redes neurais artificiais pelas suas características próprias de classificação. Vantagens como rapidez no processo de aprendizagem e flexibilidade para se adaptar a novas situações têm despertado o interesse de diversos grupos de pesquisa do sono. Outra vantagem das redes neurais é a facilidade de manuseio do conhecimento, quando comparado com a complexidade da análise de sinal, ainda mais em se tratando de sinais complexos, como são os sinais emitidos pelo cérebro humano.

1.2 Questões Específicas

- É possível utilizar técnicas de Inteligência Artificial para análise de sinais digitais ?
- A Rede Neural Artificial projetada com Alta Representação Cortical pode auxiliar no estagiamento automático das fases do sono ?
- A indexação recursiva pode ser utilizada como técnica de redução da quantidade de sinais mantendo o poder discriminatório ?

1.3 Objetivos da Pesquisa

1.3.1 *Objetivo Geral*

A principal meta deste trabalho é realizar um pré-estagiamento automático do sono utilizando um canal de eletroencefalograma. Esse sinal deverá ser coletado por um equipamento de poligrafia digital. O estagiamento do sinal será realizado por uma rede neural artificial.

1.3.2 *Objetivos Específicos*

Como objetivos específicos, este trabalho apresenta :

- a) Projetar e implementar a rede neural proposta;
- b) Melhorar a representatividade do sinal digital específico adquirido pelo sistema de poligrafia para a rede neural através de técnicas de processamento de sinal digital;
- c) Contribuir para a automação do processo de estagiamento automático, tornando-o mais rápido e também preciso.

1.4 Organização do Trabalho

Este trabalho está estruturado em 6 capítulos, onde o capítulo 1 apresentou aspectos preliminares do trabalho, bem como a apresentação do tema, sua importância, os objetivos do trabalho e sua respectiva estruturação.

O capítulo 2, dividido entre duas grandes seções, “O Sono e sua Estrutura” e a “Rede Neural Artificial”, procura dar a fundamentação teórica necessária à pesquisa. Portanto, a seção “O Sono e sua Estrutura” apresenta as características do sono humano e os seus respectivos estados, expondo também dados relativos ao sono considerado normal e os distúrbios associados ao sono anormal. Apresenta também como é realizado o processo de estagiamento do sono de forma não automática, além de apresentar alguns classificadores que se encontram em testes e estudo. A seção “Rede Neural Artificial” apresenta a forma de aquisição do sinal biológico e o seu respectivo pré-processamento como preparação dos dados para submissão à rede neural, discutida no capítulo seguinte. Para tanto, além de esclarecer o sistema de aquisição do sinal, também são abordados os passos do processamento digital sobre o sinal coletado.

O capítulo 4 tem como enfoque uma breve fundamentação da teoria das redes neurais artificiais antes de expor a rede neural desenvolvida especificamente para a tarefa proposta (estagiamento do sono).

O capítulo 5, agrupando todos os elementos estudados nos capítulos anteriores, demonstra os resultados dos testes de reconhecimento automático realizados com pacientes. A seção também descreve uma análise em torno dos resultados obtidos. Finalmente, o capítulo 6 apresenta as conclusões e recomendações finais deste trabalho.

O capítulo 7 contém a referência bibliográfica utilizada no desenvolvimento deste trabalho.

2 Fundamentação Teórica

2.1 O Sono e sua Estrutura

2.1.1 O Sono

Segundo MARTINEZ (1998), o sono não é uma função do organismo, como o caso da digestão, mas um estado alterado da consciência com inúmeras funções, muitas das quais relacionadas à conservação de energia. Como definição, CARSKADON e DEMENT (1994) escrevem que o sono é um estado comportamental reversível de desprendimento e inconsciência.

Embora não se tenha desvendado completamente o papel indispensável do sono na sobrevivência dos seres vivos, sabe-se cada vez mais sobre sua estrutura. Observando-se uma pessoa dormindo, tem-se a idéia de que o sono representa um estado único, monótono e sobretudo impenetrável. O sono era considerado assim, pois não havia método capaz de avaliar o que ocorria internamente com a pessoa dormindo. O principal instrumento para as descobertas sobre o sono foi um exame chamado polissonografia.

Graças à polissonografia, reconhece-se hoje que o sono não é um estado homogêneo, e que há dois estados distintos de sono. O sono mais surpreendente, e o último a ser descoberto, é o sono em que ocorrem movimentos rápidos dos olhos. Por suas iniciais em inglês, "*rapid eye movements*", este sono é chamado de **REM**. Apesar de ocupar apenas 20% do sono de um adulto, o sono REM é tão importante que o restante é chamado de sono **NREM** (Não REM). O sono NREM foi dividido em outras 4 fases, chamadas de estágios, de 1 a 4 (que serão devidamente explicados na seção **2.1.3.3 O Padrão de Estagiamento**).

2.1.2 A Monitorização

A maioria dos conhecimentos acerca do sono e seus estágios veio através da polissonografia, que atua como uma espécie de "radiografia" do sono. Consiste em diversos tipos de registros, como o eletroencefalograma – EEG (ondas elétricas do cérebro), o eletro-oculograma – EOG (movimentos dos olhos), eletromiograma – EMG (tensão muscular), eletrocardiograma – ECG (ondas elétricas do coração), movimentos respiratórios e a oxigenação do sangue. Assim, controla-se o funcionamento do organismo durante o sono (CARSKADON e RECHTSCHAFFEN, 1994).

A polissonografia é realizada em laboratórios do sono por meio de equipamentos especiais, e usados por técnicos capacitados. O exame normalmente dura oito horas seguidas, e ocorre, em geral, entre as 23h e as 7h. A análise do traçado, mesmo realizada com auxílio do computador, ainda exige horas de um técnico com “olho treinado” e muita paciência. Nem todos os equipamentos de polissonografia são automatizados, e poucos possuem estagiamento automático.

Dentre todos os métodos normalmente utilizados para medição dos estágios durante o sono, os principais e mais citados na literatura médica, são: EEG, EOG e EMG.




Figura 1 – Diagrama dos principais registros da polissonografia (GUIOT, 1996)

2.1.2.1 O Eletroencefalograma – EEG

O EEG é o registro elétrico contínuo da superfície do cérebro, onde a intensidade e os padrões dessa atividade contínua são determinadas, em grande parte, pelo nível global de excitação resultante do sono, da vigília e sintomas como epilepsia (SCHAUF et alii, 1993). A intensidade elétrica da onda pode variar de 0 a 200 μV , e

sua frequência pode variar de 1 a 50 Hz¹. As ondas cerebrais, normalmente, são classificadas segundo a sua frequência, sendo nomeadas como : alfa, beta, teta e delta. Segundo SCHAUFF et alii (1993), a classificação das ondas cerebrais é a seguinte :

Tabela 1 – Classificação das frequências cerebrais

Tipo	Hz
Delta	< 3,5
Teta	04 a 07
Alfa	08 a 13
Beta	14 a 25

O registro do EEG deve ser tomado diretamente do crânio segundo o sistema 10-20, cuja posição dos eletrodos obedece as normas internacionais recomendadas por JASPER em 1958 (Apud CARSKADON e RECHTSCHAFFEN, 1994). As posições dos eletrodos estão demonstradas na Figura 2. O nome desse sistema, 10-20, vem da medida feita de intervalos de 10 ou 20 % da distância total entre as 4 marcas do sistema, são elas : nasion, inion (protuberância occipital externa) e os pontos pré-auriculares direito e esquerdo.




Figura 2 - Diagrama esquemático dos eletrodos para a tomada do EEG (CARSKADON e RECHTSCHAFFEN, 1994).

Segundo CARSKADON e RECHTSCHAFFEN (1994), todas as ondas usadas para distinguir os estágios são bem visualizadas utilizando os canais C3 e C4, particularmente quando os sinais de amplitude são otimizados. Assim, é comum realizar o estagiamento do sono utilizando o canal C3 ou o C4. Entretanto, muitos laboratórios

¹ Unidade de medida de frequência definida como a frequência de um fenômeno cujo período tem a duração de um segundo; um ciclo por segundo.

também tem utilizado o registro dos canais O1 e O2 como canais auxiliares. Os autores manifestam, ainda, que o EEG é o núcleo da polissonografia, e através dele que, principalmente, os 4 estágios são distinguidos.

2.1.2.2 Eletro-oculograma – EOG

Existem duas razões para o registro do movimento rápido dos olhos. A primeira, bastante previsível, é para auxiliar a identificação do estado REM do sono. A segunda razão, mais específica, é para auxiliar a identificação do estado SEM (*Slow Eye Movement*²), que acontece na maior parte dos humanos no início do sono. Esse estado, a princípio sem função para determinação dos estágios, também pode ocorrer durante a transição do estágio 1.

O EOG é registrado através de eletrodos colocados nos cantos externos de ambos os olhos no plano horizontal, podendo usar inclusive uma posição oblíqua, ou seja, um pouco acima num dos olhos, e um pouco abaixo no outro olho (GUIOT, 1996). É importante que os eletrodos tenham a mesma referência, isto é, enquanto um dos eletrodos está referenciado pelo lobo da orelha do mesmo lado, o outro deverá ter, como referência, também o lobo da orelha do outro lado (Fig. 1). As posições desses eletrodos são conhecidas como ROC e LOC, *Right Outer Canthus*³ e *Left Outer Canthus*⁴ respectivamente.

2.1.2.3 Eletromiograma – EMG

Em um registro padrão de polissonografia, o registro da parte inferior do queixo é usado como um critério para a identificação do estágio REM. O registro de outros grupos de músculos pode ser usado como auxiliar para certos tipos de distúrbios do sono. Por exemplo, o EMG da tibia⁵ é utilizado para verificar se o pacientes possui movimentos periódicos durante o sono.

O registro para monitorização do estado REM é realizado através de 3 eletrodos localizados na parte inferior do queixo, sobre os músculos submentonianos (Fig. 1). Usa-se a derivação bipolar de um par, mantendo-se o terceiro eletrodo como reserva para ocorrência de falha de um deles.

² Movimento Lento dos Olhos.

³ Canto Externo Direito.

2.1.3 O Procedimento para o Estagiamento do Sono

2.1.3.1 O Registro Polissonográfico

Segundo GUIOT (1996), a polissonografia abrange 3 etapas distintas, as duas primeiras correspondendo à monitorização e ao estagiamento dos parâmetros eletrofisiológicos utilizados, e a última etapa à quantificação dos resultados.

Após uma noite de sono, em laboratório, os resultados são descritos pelo tempo em minutos e percentuais; algumas medidas são comuns a qualquer exame de polissonografia, independente do objetivo do estudo; outras referem-se a distúrbios específicos do sono. As medidas mais utilizadas são :

Tempo Total de Registro (TTR): considerado a partir do momento em que as luzes são apagadas e o final da noite;

Tempo de Período de Sono (TPS): considerado a partir do início do sono até o término, incluindo possíveis despertares depois do início;

Tempo Total de Sono (TTS): considerado a partir do início do sono até o término, excluindo possíveis despertares depois do início;

Ainda segundo GUIOT (1996), o sono NREM tem o tempo medido na sua totalidade, bem como de cada um de seus estágios em separado, e para a avaliação do tempo de sono REM, somam-se todos os seus períodos. Dessa forma, é possível quantificar o sono efetivamente dormido, as insônias e outros distúrbios que fragmentam o sono.

2.1.3.2 Considerações Sobre o Estagiamento

O estagiamento⁶ do registro do sono é realizado, normalmente por conveniência, em segmentos chamados de época. O tamanho médio desses segmentos é de 30 ou 20 segundos de amostra, que correspondem, aproximadamente, a uma página de papel de 30 cm registrado a uma velocidade de 10 a 15 milímetros por segundo. O estagiamento

⁴ Canto Externo Esquerdo.

⁵ O mais grosso e mais interno dos dois ossos da perna.

⁶ O padrão de estagiamento manual do sono segue critérios definidos por RECHTSCHAFFEN e KALES em 1968, que ainda são utilizados internacionalmente.

de uma época inferior a 20 segundos é considerado extremamente tedioso por muitos grupos, embora existam grupos que chegam a utilizar épocas de até 3 segundos.

Cada época é associada com o estágio que mais apropriadamente caracteriza o padrão predominante durante o intervalo examinado. Assim, o objetivo do estagiamento da época é determinar o simples fator que mais caracteriza a época. Outros tipos de medidas, como o caso da turgescência peniana durante o sono REM, conforme observado por KARACAN e SHAPIRO (1966), também podem ser utilizados para auxiliar na codificação do estágio da época em análise. Outros fenômenos, como a respiração, a saturação do oxigênio também são apontados por ASERINK e KLEITMAN (1953).

2.1.3.3 O Padrão de Estagiamento

Esta seção descreve, sumariamente, o padrão de estagiamento do sono em adultos segundo os critérios apontados por RECHTSCHAFFEN e KALES (1968). Embora esses critérios sejam utilizados para o sono adulto, também podem ser utilizados para analisar o sono de crianças e adolescentes. Normalmente, segundo CARSKADON e RECHTSCHAFFEN (1994), para recém-nascidos e bebês utiliza-se um conjunto de critérios diferentes.

Acordado (*wakeful*) : A maioria das pessoas exibe um EEG com ritmo alfa quando relaxado com os olhos fechados. Esse ritmo se altera quando o sujeito está tenso, ou mesmo com os olhos abertos. Também se encontra o ritmo alfa presente, mesmo com os olhos abertos, se o indivíduo está excessivamente sonolento. Outra característica bastante forte é o movimento voluntário dos olhos, que raramente ocorre com os olhos fechados. Outro tipo de característica também presente é a alta atividade tônica muscular. Em muitos indivíduos relaxados, o EMG pode ser indistinguível do sono NREM.



Figura 3 – EEG enquanto acordado

Sono NREM : Os quatro estágios do sono NREM são distinguíveis, principalmente, por alterações de padrão do EEG. Os dados recolhidos pelo EOG e pelo

EMG contribuem muito pouco para a diferenciação do estágio, exceto em casos específicos, como a transição do estágio 1 (onde ambos sinalizam) e o EMG (especificamente do queixo e dos olhos) para a detecção do estado REM.

Estágio 1 : O padrão do EEG do indivíduo quando em estágio 1, é descrito como atividade de relativa baixa voltagem e frequências mistas. Mista porque é comum a presença de artefatos⁷, além de pequenas faixas de atividade teta.



Figura 4 – EEG em estágio 1

Estágio 2 : O padrão do EEG do estágio 2 reflete atividade de baixa voltagem e frequências mistas. Basicamente, a diferenciação do estágio 2 para o estágio 1, se dá em dois padrões específicos que ocorrem esporadicamente. Esses padrões são conhecidos como fuso e complexo K. Os fusos são compostos por ondas de 12 a 14 cps com duração de 0,5 a 1,5 seg., enquanto que os complexos K são descritos como “ondas agudas negativas bem delineadas imediatamente seguidas por um componente positivo” (CARSKADON e RECHTSCHAFFEN, 1994, p. 950). Assim, se durante um período de 3 minutos não ocorrer nenhum desses dois eventos descritos, fusos ou complexos K, segundo a regra descrita por RECHTSCHAFFEN e KALES (1968), o traçado pode ser identificado como estágio 1.



Figura 5 – EEG em estágio 2

Estágio 3 e 4 : Os padrões de EEG dos estágios 3 e 4 são definidos pela presença de alta voltagem e ondas de atividade lenta. Conforme RECHTSCHAFFEN e KALES, no estágio 3, deve haver, para sua caracterização, um mínimo de 20% e um máximo de 50% de ondas de 2 cps com amplitudes maiores que 75 μ V de pico a pico por época (apud CARSKADON e RECHTSCHAFFEN, 1994). Pode haver ocorrência de fusos e complexos K em estágio 3.

⁷ Um artefato é um produto de arte mecânica. Neste caso, artefatos é como são chamadas ondas com vértices agudas.



Figura 6 – EEG em estágio 3

Para o estágio 4, as ondas de atividade lenta devem ser predominantes, estando presentes em pelo menos 50% na época analisada. Neste estágio os olhos não se movem, e o EMG se encontra tonicamente ativo, embora tenha uma atividade considerada baixa.



Figura 7 – EEG em estágio 4

Sono REM : O estagiamento do sono REM requer a coincidência de atividades específicas em todas as medidas eletrográficas : padrão específico do EEG, a ativação do EOG e a supressão da atividade do EMG. O padrão do EEG para o sono REM também é caracterizado por relativa baixa voltagem e frequências mistas.

Embora esse estágio se chame REM, *movimento rápido dos olhos* em inglês, o simples movimentos dos olhos não é suficiente para indicar esse estado do sono bastante particular. Isso acontece uma vez que o fenômeno, o REM, segundo CARSKADON e RECHTSCHAFFEN (1994), não é universal, pois muitos indivíduos não apresentam o movimento rápido dos olhos.

O padrão de EEG que o estado REM apresenta, por si só, é bastante similar ao estágio 2, ou seja, atividade de baixa voltagem e frequências mistas, com a presença de fusos e complexos K esporádicos. Assim, mesmo manualmente, e só através do EEG, muitas vezes é problemático diferenciar o padrão REM do estágio 2. Para que a época apresente o estado REM, além do EEG sinalizando o padrão específico, e da presença do movimento rápido dos olhos (quando for o caso), é interessante confirmar com a baixa atividade do EMG. A medida do sono REM em organismos intactos, tem sido a contração tônica dos músculos e dos reflexos, sinalizada, por exemplo, em contrações dos músculos da face.

Outra forma, bem menos utilizada, é uma regra descrita por RECHTSCHAFFEN e KALES, que diz que “um intervalo de baixa voltagem e

freqüências mistas entre dois fusos ou complexos-K é considerado estágio 2 se não houver a presença de movimento rápido dos olhos, ou movimentos estimulados nesse intervalo e se o tempo desse intervalo for menor que 3 minutos” (apud CARSKADON e RECHTSCHAFFEN, 1994, p.953).



Figura 8 – EEG em estado REM

Com a intenção de simplificar as regras para o estagiamento do sono, expomos abaixo uma tabela que procura resumir os critérios descritos acima :

Tabela 2 – Regras para o Estagiamento do Sono

Estágio	EEG	EOG	EMG
Acordado (relaxado)	Olhos fechados : ondas alfa Olhos abertos : baixa voltagem e freqüências mistas	Controle voluntário;	Atividade tônica, relativamente alta; movimento voluntário
NREM			
Estágio 1	Relativa baixa voltagem, freqüências mistas, podendo ter atividade teta com altas amplitudes	SEM	Atividade tônica fraca, podendo diminuir do estado de acordado
Estágio 2	Baixa voltagem, freqüências mistas, presença de Fusos e Complexos K	SEM ocasional próximo ao início do sono	Atividade tônica fraca
Estágio 3	≥ 20% e ≤ 50% de alta e baixa amplitude	-	Atividade tônica fraca
Estágio 4	> 50% de alta e baixa amplitude	-	Atividade tônica fraca
REM	Baixa voltagem, freqüências mistas, atividade teta e alfas lentos	REM	Supressão tônica; contração
<i>Movimento</i>	Obscuro	Obscuro	Alta atividade
<i>Sono anormal</i>	Similar ao REM	REM	Atividade tônica; contração

2.1.3.4 As Dificuldades do Estagiamento

As dificuldades de estagiar segundo os critérios apontados por RECHTSCHAFFEN e KALES (1968), são muitas, como as definições em torno do tempo, que se mostram muito imprecisas, como por exemplo : como medir o período de uma onda ? Além disso, as ondas são baseadas em padrões visuais, que são difíceis de capturar com métodos automáticos, como é o caso dos complexos K.

Outro ponto importante é que as variáveis eletrofisiológicas compreendem, basicamente, um conjunto de sinais de transição contínua, e assim, o manual de RECHTSCHAFFEN e KALES não cobre todas as possibilidades, e a interpretação dos

exames dos pacientes é deixada para especialistas. Dessa maneira, cada sono realizado em laboratório possui sua própria interpretação, e dentro desse contexto, as regras de RECHTSCHAFFEN e KALES tem funcionado mais como um guia do que propriamente como definições exatas.

2.1.4 Progresso do Sono Durante a Noite

Segundo CARSKADON e DEMENT (1994), o caso ideal de um exemplo de um sono tido como normal, pode ser configurado a partir de um jovem (homem ou mulher) adulto. O sono normal em um jovem adulto, inicia atravessando a fase NREM, sendo que a fase REM só é atingida, aproximadamente, 80 minutos depois. Essas duas fases se alternam ciclicamente durante a noite toda em períodos de, aproximadamente, 90 minutos.

2.1.4.1 O Sono Normal em um Jovem Adulto

Conforme CARSKADON e DEMENT (1994) e GUIOT (1996), o primeiro ciclo, em um adulto inicia com o estágio 1 de sono NREM, e em poucos minutos (1 a 7 minutos) avança para o estágio 2. No estágio 1 o sono é leve, e pode ser interrompido com poucos estímulos.

O estágio 2, sinalizado pelo fusos de sono, ou ainda, pelos complexos K detectados no EEG, costuma durar de 10 até 25 minutos. Para acordar um indivíduo nesse estágio, os estímulos precisam ser mais fortes que os aplicados para acordar no estágio 1. Como progresso natural do estágio 2, em 20 minutos em média, atinge o estágio 3, cujas ondas lentas são maiores que 20% e menores que 50% do sinal do EEG.

O estágio 3, de curta duração neste primeiro ciclo, serve de transição para o estágio 4. O estágio 4, caracterizado pela presença de ondas lentas, mais que 50% do sinal do EEG, costuma durar de 20 a 40 minutos, e em seguida, ocorre um retorno a estágios menos profundos. Isto é, uma passagem rápida pelo estágio 3, seguidos de 5 a 10 minutos no estágio 2, quando, após possíveis movimentos corporais, inicia-se o primeiro episódio REM, durando de 1 a 5 minutos.

Pequenas intromissões da vigília durante o sono normal ocorrem na forma de despertares breves nos quais não se recupera a consciência ou a memória. Isto se

manifesta através de 30 a 60 movimentos por noite, quando muda-se de posição ou arruma-se as cobertas, sem que se lembre disso pela manhã. Os movimentos ocorrem nas trocas de estágio e nos estágios de sono mais superficial (MARTINEZ, 1996).

Ainda segundo GUIOT (1996), o sono NREM e REM continuam alternando-se durante a noite, em torno de quatro a seis ciclos. O tempo de sono REM tende a tornar-se mais longo durante o decorrer da noite, enquanto que o sono caracterizado pelos estágios 3 e 4 tendem a encurtar na mesma medida, podendo, inclusive, desaparecer nos últimos ciclos, predominando o estágio 2 nesses casos.

2.1.4.2 O Sono Normal em um Idoso

Segundo TANKOVA e BUELA-CASAL (1996), com a idade surgem também mudanças nos parâmetros e na estrutura do sono. O primeiro ciclo, por exemplo, é mais curto, tido provavelmente como resultado da diminuição dos estágios 3 e 4. Também ocorre uma menor porcentagem do tempo total do sono, além da constância ao longo da noite, ou seja, o tempo de REM é estável durante todo o sono.

Outra observação bastante característica é o aparecimento de breves momentos de ativação, que segundo TANKOVA e BUELA-CASAL (1996), ocorrem provavelmente em consequência da interrupção do sono. Esses despertares são freqüentes e repetitivos, prejudicando o sono em indivíduos idosos. Esses dados sugerem que, com a idade, o sono se torna mais “leve”, além de aumentar a quantidade de despertares, tornado os idosos mais sensíveis a estímulos ambientais.

2.1.4.3 O Hipnograma

Uma vez estagiado o exame, uma forma bastante utilizada para visualizar o progresso do sono durante a noite é conhecida como hipnograma. Basicamente, consiste em um gráfico de linha xy cujo eixo y é tido como o tempo do sono, e o eixo x como as fases do sono. Normalmente, a ordem de apresentação das fases do sono no eixo x é : vigília, REM, Estágio 1, Estágio 2, Estágio 3 e Estágio 4.




Figura 9 - Exemplo de hipnograma

Através desse gráfico o médico pode, não apenas contar o tempo total de cada fase, mas também em que ordem essas fases aconteceram. Dessa forma é possível também verificar algum distúrbio cíclico que ocorra entre as fases REM e NREM.

2.1.5 **Generalidades sobre o sono normal**

Segundo CARSKADON e DEMENT (1994), o sono considerado normal, em um(a) jovem adulto(a), possui algumas características próprias. Entre elas, podemos verificar :

- a) O sono é iniciado pelo estado NREM;
- b) Os estados NREM e REM se alternam em períodos de 90 minutos aproximadamente;
- c) Ondas lentas predominam no primeiro terço da noite, e está ligado à iniciação do sono;
- d) sono REM predomina no último terço da noite de sono, e está ligado ao ritmo circadiano da temperatura do corpo;
- e) estágio 1 normalmente compreende de 1 a 5 % do sono;
- f) estágio 2 normalmente compreende de 45 a 50 % do sono;
- g) estágio 3 normalmente compreende de 3 a 8 % do sono;
- h) estágio 4 normalmente compreende de 10 a 15 % do sono;
- i) Considerando os estágios, o sono NREM chega a atingir 80 % do sono;
- j) sono REM compreende de 20 a 25 % do total do sono.

Esse tipo de verificação é sempre realizada sobre o padrão “jovem adulto” porque o sono é variável em função da idade (SCHAUFF, 1993). A duração total do sono e a quantidade de sono da fase 4 tendem a diminuir com o avanço da idade, sendo que o mínimo ocorre durante a meia-idade.

2.1.6 Características do sono REM

Em uma noite normal de sono e sonho, o estado de sono REM, ocorre em períodos de 90 minutos e costumam durar de 5 a 30 minutos. Segundo DEGROOT (1994), quanto mais sonolento está o indivíduo, mais curtos são os episódios de sono REM. No entanto, à medida em que o indivíduo fica mais repousado durante a noite, a duração dos episódios de sono REM também aumentam (GUYTON, 1993).

As principais, e mais importantes características acerca do sono REM são :

- a) Geralmente está associada ao sonho ativo;
- b) É mais difícil acordar indivíduos nesta fase do sono;
- c) Presença de tônus muscular por todo o corpo;
- d) A frequência cardíaca e a frequência respiratória se tornam irregulares;
- e) O encéfalo fica muito ativo durante esta fase, podendo aumentar o seu metabolismo em até 20%.

Devido à ativação do encéfalo durante o sono REM, o que torna o traçado muito parecido com o padrão de vigília, ele é também conhecido como sono paradoxal pela literatura médica.

2.1.7 Os Distúrbios do Sono

Os distúrbios do sono, bem como outros problemas relacionados com a ausência do sono, têm um impacto profundo na estrutura e na distribuição do sono. Os sintomas desses distúrbios podem ser diversos e complexos, sendo que os mais frequentes sempre são a insônia e a sonolência excessiva.

Segundo a Classificação Internacional dos Distúrbios do Sono publicada pela última vez em 1990 (a primeira foi em 1978), os distúrbios se dividem em 4 grandes grupos, são eles (BIANCO, 1996) :

Tabela 3 – Classificação Internacional dos Distúrbios do Sono

Dissônias	<ul style="list-style-type: none"> • Distúrbios intrínsecos do sono • Distúrbios extrínsecos do sono • Distúrbios do sono relacionados ao ritmo circadiano
Parassônias	<ul style="list-style-type: none"> • Distúrbios do despertar parcial • Distúrbios da transição sono-vigília • Parassônias geralmente associadas ao sono REM • Outras parassônias
Distúrbios do sono associados a alterações médico-psiquiátricas	<ul style="list-style-type: none"> • Associadas a patologias mentais • Associadas a enfermidades mentais • Associadas a outras afecções médicas
Distúrbios do sono propostos	<ul style="list-style-type: none"> • Sono curto • Sono longo • Síndrome de hipovigília • Mioclonia fragmentada • Hiperidrose do sono • Distúrbio do sono associado ao ciclo menstrual • Distúrbio do sono associado à gestação • Alucinações hipnagógicas aterrorizantes • Taquipnéia neurogênica associada ao sono • Laringoespasma relacionado ao sono • Síndrome de engasgos durante o sono

As dissônias são alterações que produzem dificuldades para o início ou manutenção do sono ou mesmo sonolência excessiva. As parassônias são alterações nas quais não estão demonstradas afecções dos processos do sono e vigília, mas se apresentam durante o sono e, em geral, produzem manifestações ou conseqüências desagradáveis para quem possui o problema. Algumas dessas conseqüências são bem conhecidas, como o sonambulismo, o pesadelo e o terror noturno. Também se enquadram neste grupo os movimentos periódicos e a apnéia (BIANCO, 1996). Os distúrbios associados a alterações médico-psiquiátricas podem ser classificados em 3 grandes grupos :

1. *Associados a patologias mentais* : é reconhecido pela comunidade médica que distúrbios psiquiátricos podem alterar a qualidade do sono.

2. *Associados a enfermidades neurológicas* : os pacientes que possuem problemas de ordem neurológica, como o caso da epilepsia, normalmente se queixam de perturbações ocorridas durante o momento de dormir ou durante as horas de sono durante a noite.
3. *Associados a outras afecções médicas* : aqui encontramos problemas relacionados a alterações do sistema orgânico, como o caso do sistema cardiovascular, respiratório e digestivo.

Finalmente, os distúrbios agrupados na classe “Distúrbios do Sono Proposto” estão relacionados com distúrbios que ainda não são bem conhecidos pela comunidade médica. Essas síndromes deverão estar melhor definidas e classificadas tão logo tenham mais informações sobre cada uma delas.

2.1.8 Estagiadores do Sono

O estagiamento do sono, normalmente, é baseado nas regras definidas por RECHTSCHAFFEN e KALES (1968), que definem o sono como composto de, basicamente, 6 estados, os estágios de 1 a 4, mais o estágio REM e o estágio Acordado. A tarefa de estagiar o sono é considerada uma tarefa tediosa, pois o registro de uma noite inteira de sono, consome, aproximadamente, 3 horas de anotações e cuidadosa observação de um técnico treinado quando executado manualmente. Por esse tipo de motivo, muito esforço tem sido gasto em projetar estagiadores automáticos de sono.

Desde o final da década de 70, diversos tipos de propostas tem sido adotadas para realizar a tarefa do estagiamento automático. Essas propostas ganharam força e, principalmente, adeptos a medida em que os computadores foram sendo introduzidos dentro das universidades. Assim, engenheiros e estudantes de pós-graduação começaram a desenvolver uma grande quantidade de sistemas de processamento de sinal e técnicas de apresentação de dados.

Entre as técnicas desenvolvidas e adotadas, podemos citar classificadores Baseados em Regras, em Análises Multidimensionais, em Análise Espectral, em Processamento de Sinal Digital, em FFT (*Fast Fourier Transform*⁸) em Sistemas

⁸ Transformada Rápida de Fourier.

Híbridos, em Classificadores Bayesianos, em Redes Probabilísticas, em matrizes de densidades espectral de cor, em Redes Neurais Artificiais e outros.

Atualmente, o problema de classificação do sono tem sido resolvido, em parte, utilizando técnicas estatísticas, ou mesmo técnicas provenientes da inteligência artificial – IA. Segundo SYKACEK et alli (1998), entre as técnicas consideradas clássicas, a mais utilizada foi a técnica chamada de KNN (*k nearest neighbour*⁹). Outras técnicas também são citadas pela literatura, como o caso da análise multidimensional sobre o EEG, aplicado por BURGER, CANTANI e WEST em 1977, ou ainda pré-processamento sobre o EEG, como meio de realizar o estagiamento, relatado por GREEN (1975).

Técnicas estatísticas e de análise espectral ainda tem sido exploradas para o estagiamento do sono, ou mesmo para o processamento de sinal. Podemos citar como exemplo o estudo realizado por BERTHOMER, PRADO e BENOIT (1997), cujo trabalho propõe a utilização de filtros para analisar os canais de EEG. Os autores também apontam características que podem ser utilizadas como meio de detecção do estágio do sono. Contudo, BENTRUP e RAY (Apud SYKACEK et alli, 1998) relatam que essas técnicas, em geral, possuem um performance inferior as técnicas baseadas em IA.

Entre as técnicas baseadas em IA, pesquisadores tem utilizado o aprendizado indutivo para construir árvores de decisão e classificadores baseados em regras, como é o caso de uma aplicação do C4.5¹⁰, relatado por LANGLEY e SIMON em 1995, e KUFURIN em 1997. Outro tipo de proposta já apresentada, também baseada em conhecimento, é a utilização de sistemas especialistas para a realização do estagiamento, proposto por RAY, LEE e MORGAN em 1986. Os testes foram realizados em registros de 7 pacientes, e demonstraram resultados em torno de 89%. Utilizando um Sistema Especialista para estagiar o sono de 6 pacientes, PRINCIPE et alli (1993) relata uma média de acerto em torno de 86 %. Outro exemplo da utilização de regras é o trabalho apresentado por NIELSEN et alii (1997) que, usando os sinais do EEG e do EOG, utilizou uma rede probabilística (*Causal Probabilistic Network - CPN*) para realizar o estagiamento automático do sono em 6 pacientes. Como comparação, NIELSEN et alii usou o estagiamento manual realizado por dois especialistas como

⁹ Vizinhança mais próxima de k.

referência. Os resultados obtidos por NIELSEN tiveram uma concordância de 68% a 71%.

Redes Neurais Artificiais - RNAs também têm sido utilizadas para classificação do sono partindo de treinamentos realizados com exemplos selecionados. Neste contexto, o trabalho de SCHALTENBRAND (1995) tem se mostrado interessante. Utilizando uma rede neural perceptron multicamada, SCHALTENBRAND tem conseguido resultados de até 82% de acerto. Uma taxa bastante próxima da taxa de 85% de média de acerto conseguida por PRINCIPE et alli (1993) em testes realizados em uma população de 6 pacientes.

Outro exemplo do uso de redes neurais artificiais e EEG é o trabalho de SHIMADA e SHIINA (1997), do Instituto de Ciência de Informação e Eletrônica da Universidade de TSUKUBA, no Japão. SHIMADA e SHIINA utilizaram uma rede neural com aprendizado *backpropagation* para detectar características próprias das ondas de sono através do EEG (ondas alfa, corcundas e ondas longas). Conforme seus resultados, obtiveram taxas de acerto de até 90% para ondas alfa, e até 70% de acerto para as lentas (teta e delta). Também tem sido utilizados outros paradigmas de redes neurais, como o caso de redes neurais não supervisionadas. Exemplo deste método é o trabalho de LOSSMANN (1996), que utilizou redes neurais de Kohonen para produzir um semi-estagiamento semi-automático. Podemos dizer semi-estagiamento uma vez que o trabalho de LOSSMANN não dividiu os estágios conforme as definições recomendadas por RECHTSCHAFFEN e KALES (1968), mas segundo critérios próprios que reduz o número de estágios.

A quantidade de trabalhos que procura combinar o uso de RNA com alguma outra técnica de IA (híbridos) também tem aumentado de forma significativa. É certo que as RNA atuam em conjunto com técnicas de processamento de sinal digital, uma vez que é requisito necessário para o tratamento do sinal proveniente do coletor digital. Podemos citar, por exemplo, BAUMGART-SCHMITT et alii (1997), cujo trabalho utiliza algoritmos genéticos e algoritmos evolucionários para a otimização da rede neural. Os resultados alcançados por BAUMGART-SCHMITT et alii (1998) alcançam até 80% de concordância. Outra combinação publicada é a utilização de inferência Bayesiana em conjunto com uma RNA de 2 camadas, conforme proposta por

¹⁰ Ferramenta utilizada para construção de árvores de decisão e classificadores baseados em regras.

SYKACEK et alli (1998), cujos resultados apresentam uma performance de 82%. Segundo SYKACEK et alli (1998), os bons trabalhos de estagiamento baseado em redes neurais tem apresentado performances que variam de 75% a 85 % de acerto.

Também encontra-se outros tipos de classificadores de sono, cujos objetivos são mais específicos e voltados mais para a detecção de características próprias, como o caso dos distúrbios do sono. Podemos citar o trabalho de HADJIYANNAKIS et alii (1997), cujo objetivo é detectar a transição do estado NREM para o estado REM do sono. Para isso, HADJIYANNAKIS tem utilizado a FFT sobre os sinais do EEG. Alguns destes classificadores também são baseados em redes neurais, como é o caso do trabalho de POHL (1995), cujo objetivo é reconhecer os complexos K durante o sono em sinais de EEG. Para tanto, POHL utiliza uma rede neural fuzzy, que apresenta uma taxa de acerto em torno de 50 %.

2.1.8.1 O Mercado

Comercialmente, o mercado é suprido por diversos equipamentos de poligrafia que realizam a aquisição de sinais como o EEG, o EOG e o EMG de forma digital, citando por exemplo, o coletor portátil “Easy II Console”, da empresa americana CADWEL, ou ainda, o coletor “BT-4000” da empresa brasileira EMSA, situada no Rio de Janeiro.



Easy II Console (CADWEL)

BT-4000 (EMSA)

Figura 10 – Coletores de Sinal Eletrofisiológico

No entanto, não são muitos os sistemas que realizam o estagiamento automático, ou mesmo semi-automático do sono. Entre os sistemas que realizam esse tipo de estagiamento, destacamos o “Nightingale Polygraphic Sleep Analyser”, da empresa dinamarquesa “Judex Datasusteme”, e o “Sleep Stage Scoring”, da Universidade de JOENSUU (Finlândia), cujo estagiamento é semi-automático.

O sistema “Nightingale” da Judex Datasystems (JUDEX, 1998), foi idealizado, inicialmente, dentro da Universidade de AALBORG (Dinamarca) pelo Departamento de Informática Médica, e somente depois foi realizada uma parceria comercial com a empresa Judex Datasystems para finalizar o produto. O “Nightingale” extrai a informação espectral do EEG usando modelos autoregressivos, e combinado os movimentos dos olhos, através do EOG, e a atividade muscular através do EMG, estes são passados por um classificador baseado em regras. Para aumentar o poder de classificação, especificamente sobre os distúrbios do sono, pesquisas que combinam parte do analisador já existente, com redes neurais artificiais e métodos probabilísticos se encontram em andamento (MEDICAL, 1996).

O sistema “Sleep Stage Scoring” – SSS, do Departamento de Matemática da Universidade de JOENSUU (Finlândia), está sendo realizado como parte do projeto EUROMED¹¹ (LOSSMANN, 1997). O sistema SSS procura aplicar transformadas de wavelets e modelos de autoregressão, além de redes neurais (mapas de Kohonen) para o processamento do sinal digital de forma que atue sobre o estagiamento do sono. Pela característica semi-automática do SSS, o sistema realiza o estagiamento em 3 fases : seleção, treinamento e estagiamento. Na fase de seleção, o operador deve selecionar algumas épocas características de cada estágio que se deseja identificar do sinal de EEG. Na fase de treinamento, as épocas selecionadas são submetidas à rede neural de Kohonen para classificação. Na última fase, do estagiamento, o sistema, partindo da rede neural treinada com as épocas selecionadas, submete o restante das épocas para a respectiva classificação.

¹¹ O Projeto EUROMED é financiado pela Comissão Européia DG III, e tem por objetivo o desenvolvimento de sistemas na área de medicina. (<http://narcisus.esd.ece.ntua.gr/~www/euromed.html>)

2.2 Rede Neural Artificial

2.2.1 Breve História

As redes neurais foram desenvolvidas, originalmente, na década de 40, pelo neurofisiologista McCulloch e pelo matemático Walter Pitts, da Universidade de Illinois, os quais, dentro do espírito cibernético da época, publicaram um artigo intitulado “*A Logical Calculus of the Ideas Immanent in Nervous Activity*”. O trabalho consistia em uma analogia entre células nervosas vivas e um processo eletrônico binário (KOVACS, 1996).

Atualmente, encontramos modelos de redes neurais artificiais bem diferentes, e também mais complexos do que o modelo apresentado por McCulloch e Pitts na década de 40. Entre os modelos mais populares, podemos citar, por exemplo: Perceptron, Adaline e Madaline, Backpropagation, Rede de Hopfield, Mapas de Kohonen, modelo ART (Teoria da Ressonância Adaptativa), entre outros. O modelo Perceptron, talvez o mais famoso, foi criado em 1957 por Frank Rosenblatt (TAFNER, 1995), e atualmente é utilizado apenas como um modelo didático, uma vez que representa bem a estrutura e a dinâmica de uma rede neural.

2.2.2 Ciclo de Vida de uma Rede Neural

A rede neural possui dois momentos de explicitação do processamento: o momento de *aprendizado* e o momento de *utilização* (a aplicação da rede de fato). Esses dois momentos de operação são bem distintos e aplicados em períodos diferentes no ciclo de vida da rede.

O *aprendizado* é um processo de ajuste dos pesos das conexões em resposta ao estímulo apresentado à rede neural. Ou seja, a rede possui a propriedade de modificar-se em função da necessidade de aprender a informação que lhe foi apresentada. Já o processo de *utilização* é a maneira pela qual a rede responde a um estímulo de entrada sem que ocorram modificações na sua estrutura.

Todavia, o projeto de criação e utilização da rede neural pode ser organizado num processo de implementação de 4 fases diferentes para consolidar uma utilização mais segura. O ciclo de vida de uma rede, como é conhecido, é composto pelas seguintes fases: Definição, Treinamento, Utilização e Manutenção.




Figura 11 - Ciclo de vida de uma Rede Neural (TAFNER, 1995).

2.2.3 Estrutura da Rede Neural Artificial

Para um melhor entendimento das redes neurais, LOESCH e SARI (1996) sugerem que a descrição estrutural da rede neural seja dividida em diferentes níveis, são eles :

1. Micro-Estrutura: definição das características de cada neurônio artificial da rede neural;
2. Meso-Estrutura: definição da organização da rede neural;
3. Macro-Estrutura: orientação do formato e modelagem da rede neural, procurando compreender a aplicação para a resolução de problemas reais.

2.2.4 O Neurônio Artificial (Micro-Estrutura)

Tendo o neurônio biológico como modelo, o neurônio artificial, também conhecido como Elemento de Processamento, em geral, possui uma estrutura que procura simular o comportamento do neurônio biológico (TAFNER, 1995).

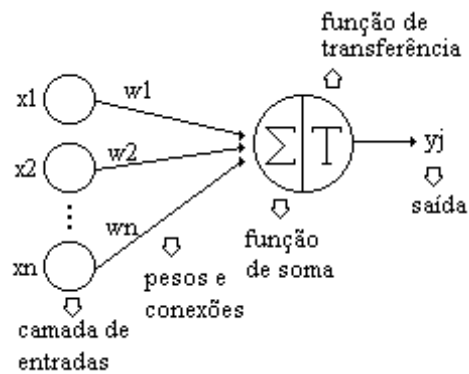


Figura 12 - Neurônio Artificial

A Figura 12 mostra o modelo geral de um neurônio artificial – NA, sendo que cada NA é numerado e indexado por j . Traçando uma analogia com neurônios biológicos, os NA também apresentam muitas entradas (*camada de entrada*), conectadas com o neurônio através dos pesos (*dendritos*). Uma função específica chamada de *função de soma*, simulando a captação do estímulo presente nos dendritos, acumula de maneira ponderada (através dos pesos), os dados recebidos das entradas do neurônio em s_j :

$$s_j = \sum_{i=1}^n x_i \cdot w_{ji} \quad (1)$$

Conseguido o valor da soma ponderada, a *função de transferência* do NA utiliza um limiar θ para determinar a sua ativação ou não em y_j :

$$y_j = f(s_j) = \begin{cases} 1 & s_j \geq \theta \\ 0 & s_j < \theta \end{cases} \quad (2)$$

Assim, a saída do neurônio será 1 somente se a soma ponderada for maior que θ , onde θ pode ser comparado, por analogia, com o limiar de ativação do neurônio biológico.

O potencial de ação de um neurônio biológico acontece ou não, dependendo da grandeza do estímulo que é aplicado à ele. O limiar é definido como o valor mínimo do potencial de membrana em que vai ocorrer o potencial de ação. Todos os valores de potencial de membrana inferiores ao valor necessário para a produção de um potencial de ação são ditos subliminares. Caso um estímulo não consiga deslocar o potencial de

membrana até o valor limiar, a resposta parcial, subliminar, desaparece. No neurônio artificial, temos uma situação semelhante, cujo limiar de disparo é operado pela função de transferência.




Figura 13 – Potencial de ação mediante a despolarização celular

Contudo, em alguns modelos de redes, o nível de saída produzido pela função de transferência pode ser, inclusive, igual a soma ponderada. Muitas vezes, essa função possui características sigmas ou ríspidas, e assim, o neurônio pode não produzir efeito no neurônio seguinte se o valor de ativação estiver abaixo de um valor mínimo para sua ativação.

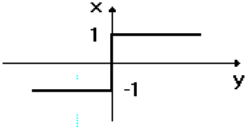
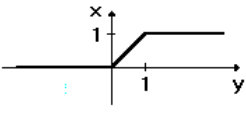
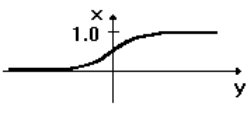
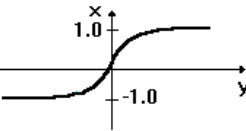
<p style="text-align: center;">Hard Limiter (limite ríspido)</p>  $y = f(x) = \begin{cases} -1 & x < 0 \\ 1 & x \geq 0 \end{cases}$	<p style="text-align: center;">Ramping Function (função de rampa)</p>  $y = f(x) = \begin{cases} 0 & x < 0 \\ x & 0 \leq x \leq 1 \\ 1 & x > 1 \end{cases}$
<p style="text-align: center;">Sigmoide Function (função sigma)</p>  $y = f(x) = \frac{1}{1 + e^{-x}}$	<p style="text-align: center;">Sigmoide Function (função sigma)</p>  $y = f(x) = \begin{cases} 1 - \frac{1}{1 + x} & x \geq 0 \\ -1 + \frac{1}{1 - x} & x < 0 \end{cases}$

Figura 14 - Funções de transferências conhecidas (TAFNER, 1995)

2.2.5 Arquitetura e Dinâmica das Redes Neurais (Meso-Estrutura)

Neste nível, é considerada a organização e o arranjo físico dos neurônios artificiais na rede neural, pois é a combinação desses neurônios artificiais e suas conexões, mais o algoritmo de aprendizado usado para o treinamento, que formam a rede neural artificial. Segundo LOESCH e SARI (1996), para caracterizar esses agrupamentos de neurônios, devem ser considerados :

- o número de camadas da rede;
- o número de neurônios por camada;
- o tipo de conexões : *forward*, *backward*, lateral;
- o grau de conectividade entre os neurônios : um a um, total, randômica, etc.

Essas características modificáveis são importantes para distinguir classes diferentes ou tipos de arquiteturas de redes neurais. Assim, segundo HAYKIN (1994), podemos classificar as redes neurais em até 4 classes estruturais, são elas :

1 Redes *feedforward* de simples camada

São redes de neurônios organizados em forma de camadas. Possui uma camada de entrada que projeta seus valores para a camada de saída, mas não o contrário, por isso o nome *feedforward*.




Figura 15 - Rede neural com simples camada de neurônios

2 Redes *feedforward* de múltiplas camadas

Este tipo de rede neural possui, em relação às redes da classe 1, a presença de camadas escondidas de neurônios. A função desses neurônios escondidos é intermediar a camada de entrada e a camada de saída da rede neural.




Figura 16 - Rede neural com duas camadas de neurônios

3 Redes recorrentes

Essas redes possuem uma diferença significativa em relação às redes neurais tipo *feedforward*, a retroalimentação. Por exemplo, esse tipo de rede pode possuir uma ou mais camadas de neurônios que alimentam a entrada dos outros neurônios da mesma camada com o seu sinal de saída.




Figura 17 - Rede neural com retroalimentação

4 Estruturas de Lattice

É uma rede neural tipo *feedforward* cuja característica é a disposição espacial, ou seja, os neurônios da camada de saída estão arranjados sob a forma de linhas e colunas, obedecendo um senso físico. Essa disposição espacial pode ter n dimensões.




Figura 18 - Rede neural com duas dimensões Lattice, 3 x 3 neurônios

2.2.5.1 Entradas e Saídas

Quanto às entradas das redes neurais, LOESCH e SARI (1996) apontam que determinadas arquiteturas de redes trabalham com tipos de entradas próprias, como sinais digitais, valores reais, valores binários, ou ainda, sinais analógicos. A camada de entradas de uma rede neural, é formalizada por muitos autores como vetor de entrada x . Essa camada apenas faz a ligação dos dados de entrada com a rede neural, projetando os valores das entradas para os neurônios.

Quanto às saídas das redes neurais, algumas dependem da classificação dos dados de entrada, outras podem produzir padrões de saídas em resposta às entradas, ou mesmo criar complementações das entradas. Normalmente, a camada de saída é formalizada como y (KOVACS, 1996).

2.2.5.2 Treinamento

Procurando simular sistemas biológicos, a rede neural também procura reproduzir a capacidade de “aprender”. HAYKIN (1994, p.45) define o termo aprendizado, dentro do contexto das redes neurais artificiais como “*um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo contínuo de estimulação do ambiente no qual a rede está inserida.*” Dessa maneira, havendo um processo de aprendizado, deve haver, portanto, um procedimento para ensinar. E é exatamente pela estimulação que a rede neural é “treinada” para reter conhecimento em suas conexões.

O tipo de treinamento mais utilizado, e também o mais intuitivo, é o treinamento através de exemplos. Por este método, são apresentados exemplos de comportamento à rede, isto é, para um estímulo x_i deve haver uma saída y_i^d , onde o índice d refere-se à saída desejada. Os exemplos devem ser repassados à rede até que a rede aprenda o comportamento correto, ou seja, até que as diferenças $|y_i^d - y_i|$ para todos os $i=1,2,\dots,n$ seja mínima (KOVACS, 1996).

Para formalizar melhor o método de treinamento através de exemplos, é imprescindível definir um conjunto ψ com i exemplos de treinamento, formando então o chamado *conjunto de treinamento*:

$$\psi = \{(y_i^d, x_i)\}_{i=1}^n \quad (3)$$

Onde os x_i são as entradas que deverão gerar as saídas y_i^d , fazendo com que cada exemplo seja um par do tipo (y_i^d, x_i) .

2.2.5.3 O Algoritmo de Aprendizado

O algoritmo de aprendizado da rede neural possui grande significância, uma vez que ele é o responsável pela habilidade de aprendizado conferida à rede neural (HAYKIN, 1994). O aprendizado da rede neural é realizado através de um processo iterativo de ajuste aplicado às conexões (pesos) e aos limiares dos seus neurônios.

Essa definição do processo de aprendizado, sustentada por HAYKIN (1994), implica na seguinte seqüência de eventos:

1. A rede neural é estimulada por um ambiente;
2. A rede neural se modifica como resultado da estimulação;
3. A rede neural responde de uma nova forma ao ambiente devido as mudanças ocorridas em sua estrutura interna.

O processo de ajuste sináptico pode ser executado por diversas regras diferentes. As mais conhecidas, ainda segundo HAYKIN (1994) são: aprendizado erro-correção, aprendizado de Hebb, aprendizado competitivo e aprendizado de Boltzman. O aprendizado erro-correção é baseado em filtro ótimo. O aprendizado de Hebb e o aprendizado competitivo são inspirados em estudos neurobiológicos, e o aprendizado de Boltzman é baseado na termodinâmica e na teoria da informação.

Para exemplificar o processo de ajuste dos pesos, utilizaremos o princípio de aprendizado de Donald Hebb, também conhecido como a Regra de Hebb¹². Segundo a regra (KOVACS, 1996), o vetor de pesos (w_j) do neurônio j deve ser atualizado da seguinte forma :

$$w_j^{novo} = w_j^{velho} + \Delta w_j^{velho} \quad (4)$$

onde w_j^{novo} = novos pesos do neurônio j

w_j^{velho} = pesos antigos do neurônio j

sendo que

$$\Delta w_j = \alpha \cdot (y_i^d - y_j) \cdot x_i \quad (5)$$

onde α = taxa de aprendizado, refletindo a taxa com que os ganhos são alterados

y_j = saída obtida do neurônio j após a apresentação do estímulo x_i

y_i^d = saída desejada para o estímulo x_i

x_i = estímulo apresentado nas entradas do neurônio j

¹² Regra baseada num princípio de aprendizado neural publicado pelo biólogo Donald Hebb em 1949 no livro "The Organization of Behavior".

2.2.6 Paradigma de Aprendizado

Outro aspecto relevante quanto ao aprendizado é o paradigma envolvido. Segundo HAYKIN (1994), existem 3 paradigmas diferentes para condução do aprendizado em redes neurais, são eles : supervisionado, reforço e não supervisionado. O aprendizado supervisionado, como o próprio nome sugere, é realizado sob a supervisão de um “professor” externo. O paradigma do reforço acontece utilizando o processo de tentativa e erro através de um “crítico”. Finalmente, aprendizado não supervisionado é baseado na auto-organização, que dispensa a utilização, tanto do “crítico” quanto do “professor”.

2.2.7 Modelagem das Redes Neurais (Macro-Estrutura)

A macro-estrutura das redes neurais é considerada sempre que surge a necessidade de modelar a rede para um problema de aplicação qualquer. A modelagem pode compreender aspectos como o tamanho da rede, o número de camadas, o tipo de conexão e o grau de conectividade da rede neural. Muitas vezes envolve também aspectos que englobam a combinação e fusão de outras arquiteturas de redes neurais, criando então as chamadas redes híbridas, onde mesmo combinadas, cada qual guarda sua arquitetura distinta.

2.2.8 Aplicação das Redes Neurais

Entre as tarefas mais comumente utilizadas pelas redes neurais, estão:

- Predição (meteorologia, oceanografia, economia, bolsa de valores,...);
- Processamento de sinais complexos (radar, ruído,...);
- Diagnósticos (máquinas, homens,...);
- Ajuste de curvas;
- Reconhecimento de fala;
- Reconhecimento de imagens (Sensoriamento Remoto,...);
- Classificação de sinais;

2.2.9 Porque Usar Redes Neurais Artificiais

São muitos os motivos que nos levaram a utilizar a tecnologia das redes neurais artificiais como proposta para o estagiamento automático do sono. Entre eles podemos citar :

- a capacidade de generalização da rede neural;
- a rede possui aprendizado por exemplos;
- a capacidade de adaptação a novas situações pela mudança dos pesos;
- e a capacidade de decisão sobre fatos ruidosos ou mesmo danificados.

Em todo o caso, um grande motivo também foi a facilidade de implementação da rede como suporte ao sistema de polissonografia. A aprendizagem por exemplos facilitou também a aquisição do conhecimento acerca das características de cada fase do sono, não havendo assim a necessidade de programação.

3 A Rede Neural Artificial no Estagiamento Automático do Sono

3.1 Introdução

Para a utilização de uma rede neural artificial como meio de reconhecimento de um sinal advindo de um EEG, não basta simplesmente “jogar” o sinal na rede neural e esperar que a mesma aprenda e o reconheça. Utilizar redes neurais artificiais significa também conhecer os dados que estão sendo submetidos à rede, e portanto, é fundamental que o projetista conheça, não somente a arquitetura da rede neural utilizada, mas também a natureza e a forma da informação submetida à ela.

Diante deste contexto, utilizou-se técnicas de pré-processamento, ao qual o sinal do EEG é submetido, com a razão única de melhorar a sua representatividade e aguçar o desempenho da rede neural. O pré-processamento utilizado neste trabalho é discutido em uma seção própria dentro deste mesmo capítulo.

Da mesma forma, a arquitetura neural também deve ser conhecida pelo projetista, e portanto, deve ser realizada com a mesma proposta utilizada para a representação do sinal de informação. Neste caso, utilizamos uma rede neural já explorada por TAFNER e BARCIA em 1996 para reconhecimento de palavras faladas, e depois aperfeiçoada por TAFNER em 1998. Para demonstrar o aperfeiçoamento, TAFNER utilizou novamente o problema do reconhecimento de palavras faladas. A rede citada, conhecida como ARC por suas características plásticas é apresentada neste capítulo em uma seção própria.

O capítulo também apresenta, de uma forma um tanto sucinta, o software desenvolvido para o reconhecimento que congrega tanto o pré-processamento quanto a rede neural ARC.

3.2 O Pré-Processamento

3.2.1 O Sinal do EEG

Os dados adquiridos pelo sistema POLIWIN são submetidos a uma série de processos com o objetivo de aumentar a representatividade deles em relação ao sistema. Esse aumento da representatividade é necessário pois pode separar o ruído da informação propriamente dita.

O pré-processamento dos dados deste trabalho consiste, então, em 3 fases diferentes, cada uma das fases dá à informação biológica adquirida uma nova interpretação. A atuação de uma fase sobre os resultados obtidos na fase anterior constitui o pré-processamento para este trabalho. As fases são assim denominadas :

- Corte do Sinal Digital;
- Geração dos Índices Recursivos;
- Extração de Características.

3.2.2 Corte do Sinal Digital

O sinal capturado pelo equipamento de polissonografia contém ruídos que podem confundir as fases seguintes no pré-processamento. Assim, é necessário que um processamento anterior procure amenizar a presença de ruídos (sinais de altíssima amplitude em módulo) e ajustar o sinal para as fases que se seguem. A amenização de ruídos é realizada através de um corte sobre os sinais que extrapolam os limites definidos (limite superior e inferior). Após os sinais ajustados aos novos limites, converte-se todos os sinais negativos no seu simétrico.




Figura 19 – Trecho do sinal biológico original com os limites superior e inferior

3.2.3 Geração dos Índices Recursivos

Utilizou-se também uma técnica chamada Indexação Recursiva (INREC), cuja tarefa é, segundo SOUZA (1998), encontrar uma transformação que leve um vetor de um espaço \mathfrak{R}^n para um espaço de valores numéricos unidimensional \mathfrak{R} , que mantenha a capacidade de identificar os pontos próximos em ambos os espaços. A intenção é conseguir reduzir o espaço de características dos padrões de dimensão p de um determinado domínio de problema a um valor numérico (índice) $\rho \in \mathfrak{R}$, mantendo o poder discriminatório. Assim, seja um padrão x_i representado pelas suas p características, define-se um índice ρ como:

$$\rho = f(x_1^a f(x_2^a f(x_3^a \dots f(x_p^a) \dots))) \quad (6)$$

onde f é a função para a recursão, x_k são as p características do padrão x_i , e $a \in \{1, -1\}$. Dessa forma, temos ρ como resultado de uma recursão ou composição de uma função matemática aplicada sobre o padrão original.

Procurando aplicar essa técnica como parte do pré-processamento, utilizou-se a INREC para reduzir a quantidade de sinais, sem perda de informação. Isso foi realizado aplicando-se a INREC sobre segmentos dos sinais digitais originais, após a primeira fase. Cada segmento foi substituído pelo seu respectivo índice, construindo assim um novo vetor representando o sinal original. Para a construção desse vetor de índices utilizou-se a função $f = \text{tangente hiperbólica}$.




Figura 20 – Vetor de índices

3.2.4 Extração das Características

Chamamos de características, neste trabalho, a contagem da presença de sinais do vetor de índices em determinadas faixas de amplitudes. Para tanto, primeiramente, toma-se uma partição do vetor de índices com P intervalos iguais. A partição é definida em relação ao tamanho do vetor (domínio), e não em relação às amplitudes (imagens).




Figura 21 – Definição dos Intervalos da Partição

Uma vez particionado, obtém-se as posições de cada corte. Em seguida, ordena-se o vetor de índices e gera-se as faixas de amplitudes tomando-se a imagem de cada corte.




Figura 22 – Faixa de amplitudes e elemento de partição para o vetor de índices

Tendo as faixas de amplitudes delimitadas, a extração de características é realizada tomando-se um determinado tempo do vetor de índices original. As características são geradas então através da contagem da presença dos sinais nas faixas de amplitudes respectivas. O número de elementos da partição define a quantidade de características. A contagem pode ser feita também utilizando apenas os máximos locais.

3.3 Rede Neural Artificial com Alta Representação Cortical – ARC

3.3.1 Arquitetura

A arquitetura proposta neste trabalho, chamada de rede neural ARC, foi projetada com base em uma estrutura de rede tipo Lattice, de aprendizagem supervisionada, tipo *feedforward*, amplamente conectada cuja disposição dos neurônios é bidimensional. Apesar de sua estrutura parecer ser similar à apresentada por KOHONEN (1989), ela possui muitas características próprias que diferem bastante da rede original de KOHONEN.

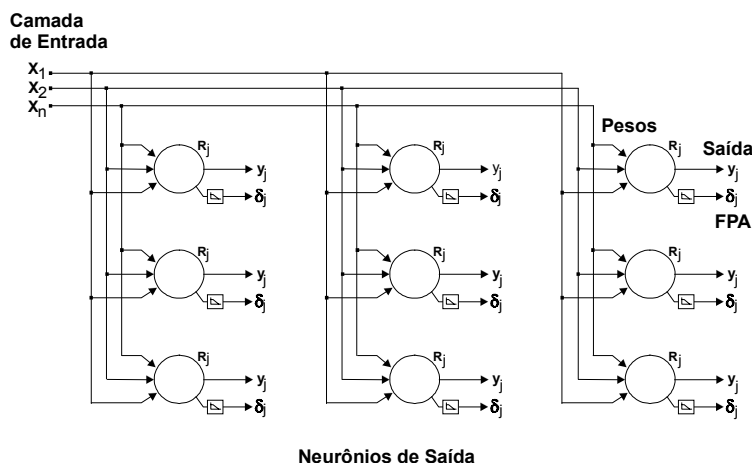


Figura 23 – Todas as entradas estão conectadas com as saídas (neurônios)

Esta rede, além de possuir alterações no algoritmo de aprendizagem, possui também, implementada em seu código, determinadas instruções que procuram reproduzir outras propriedades do tecido neural, como é o caso da alta representação cortical e dos trens de disparos dos neurônios estimulados, também conhecido como atividade neural repetitiva (SCHAUFF et alli, 1993).

3.3.2 Características

O neurônio da rede ARC possui duas características próprias que os diferencia em relação à estrutura normal dos neurônios artificiais. A *Força do Potencial de Ação* (FPA) e o *Rótulo*. Esses dois atributos participam ativamente do processo da expansão cortical, outro atributo da rede que é caracterizado pela capacidade de crescimento da rede.

A implementação dessa característica de crescimento da rede é baseada em estudos onde mostram que a cada nova percepção, ou memorização, ocorre a expansão de antigas estruturas, onde simplesmente são adicionadas às estruturas já existentes FUSTER (1997).

Para QUARTZ (1993), seguindo uma linha de pensamento que procura dar crédito a expansibilidade das redes neurais artificiais, a premissa de um sistema que tenha capacidade para alterar sua arquitetura adicionando novos neurônios artificiais, e assim modificar as conexões sinápticas envolvidas nessa mudança arquitetural, pode ser considerada como uma interpretação natural do construtivismo em termos de aprendizado de redes neurais artificiais¹³.

Outra característica marcante da arquitetura ARC que pode ser ressaltada é a opção da ausência ou não de inúmeras iterações para treinar a rede neural, ocorrendo a assimilação de um fato com apenas uma apresentação do conjunto de treinamento à rede neural.

3.3.3 Alta Representação Cortical – ARC

Esta rede neural é chamada de ARC pela característica de haver muitos neurônios respondendo a um mesmo estímulo. Assim, partindo da idéia que uma rede neural seja, por simples analogia, a representação de um córtex artificial, temos uma representação cortical para cada novo estímulo que seja aprendido por ela.

¹³ Conforme QUARTZ, a caracterização de um sistema que possa somar estruturas através do aprendizado não é uma exclusividade das redes neurais artificiais, algoritmos baseados em Turing também podem ser formulados de forma que produzam resultados similares.

E para evitar que todos os neurônios respondam da mesma forma quando apresentado um estímulo à rede, é atribuído, a cada neurônio, uma resposta com intensidade diferente determinada em tempo de treinamento conforme a disposição espacial, agrupando os estímulos em regiões específicas.




Figura 24 – Disposição de representações em um córtex artificial

Havendo mais neurônios respondendo ao mesmo estímulo, e em intensidades diferentes, teremos também um leque maior de possibilidades de acerto dessa rede neural. Assim, dependendo da variação do estímulo, podemos ter neurônios vencedores diferentes, mas na mesma área representacional. Essas pequenas variações podem ser fortes o bastante para modificar a estrutura do sinal, mas não o suficiente para descaracterizá-lo.

3.3.4 A Conectividade da Rede Neural

A camada de entrada da rede neural, cujos elementos estão conectados com todos os neurônios da rede neural (Figura 23), é representada matematicamente por um vetor de entrada denotado por X_i (i-ésimo padrão de entrada):

$$X_i = [x_1, x_2, x_3, \dots, x_p] \in \mathcal{R}^p \quad (7)$$

As conexões de cada neurônio j da rede neural são representadas por um vetor, denotado por w_{ji} (i-ésima entrada):

$$w_{ji} = [w_1, w_2, w_3, \dots, w_p] \in \mathcal{R}^p \quad (8)$$

O vetor w_{ji} é inicializado com valores, normalmente, escolhidos aleatoriamente. Esses valores devem representar a faixa de valores que compõem os fatos a serem treinados.

3.3.5 O neurônio

O neurônio da rede ARC também possui uma proposta diferenciada em relação à estrutura normal dos neurônios artificiais. O neurônio j possui, além da saída y_j , outras duas informações, a Força do Potencial de Ação, denotado por δ_j , e o rótulo, denotado por R_j .




Figura 25 – Neurônio artificial da rede neural ARC

3.3.5.1 A Saída do Neurônio (y)

Uma vez tendo o vetor de entrada x_i , o resultado presente em y_j é conseguido através da distância euclidiana entre os pesos do neurônio, w_{ji} , e as entradas da rede neural, x_i . Assim, temos y como sendo :

$$y_j = \|x_i - w_{ji}\| \quad (9)$$

onde: x_i = i -ésima entrada

w_{ji} = pesos do neurônio j para a i -ésima entrada x_i

y_j = distância euclidiana para o neurônio j

3.3.5.2 A Força do Potencial de Ação da Saída

A idéia da Força do Potencial de Ação, δ_j , é baseada na atividade neural repetitiva dos neurônios biológicos, cuja função é transmitir informação sobre a intensidade do estímulo. Segundo SCHAUFF et alli (1993), quando uma despolarização prolongada resulta da ação de muitos potenciais sinápticos ou de receptores sobre a região receptiva da célula, pode ser produzida, muitas vezes, uma série de potenciais de ação no axônio. Esse tipo de resposta é conhecido como *atividade repetitiva neural* (ou simplesmente, trem de impulsos).




Figura 26 – Atividade repetitiva perante a despolarização prolongada

Dessa forma a *atividade repetitiva* é importante por permitir que os potenciais de ação, do tipo tudo-ou-nada, transmitam informação sobre a intensidade do estímulo, em termos da relação entre a intensidade do estímulo e o número de potenciais de ação.

A *atividade repetitiva neural* foi simulada nos neurônios artificiais da rede ARC utilizando princípios simples de intensidade de resposta. Basicamente, a idéia é atribuir também uma intensidade ao grau de proximidade entre o estímulo apresentado nas entradas e os pesos dos neurônios da rede neural. Essa intensidade é chamada de *Força do Potencial de Ação*, ou simplesmente δ .

A Figura 27 exibe um gráfico que demonstra a forma de obtenção do δ através de uma atribuição de intensidade, medida de 0 a 100%, conforme a resposta obtida em y_j . O gráfico apresentado (figura 023) exibe os valores já normalizados.




Figura 27 – Força do Potencial de Ação do neurônio j

Assim, o resultado de δ_j , conseguido após o neurônio ter o resultado de y_j , é obtido através da seguinte equação:

$$\delta_j = f(y_j) = \begin{cases} 100 & y_j \leq 0.2 \\ 0 & y_j > 1 \\ |1 - y_j| * 100 & 0.2 < y_j \leq 1 \end{cases} \quad (10)$$

onde : δ_j = Força do potencial de ação do neurônio j

y_j = Distância euclidiana do neurônio j

Dessa forma, as variações da intensidade do estímulo ficam por conta da faixa de 0.2 a 1 como resultado do y_j dos neurônios artificiais.

3.3.5.3 O Rótulo do Neurônio

O rótulo do neurônio carrega a representação neural do estímulo, pois nesta rede cada neurônio tem o poder de representação de um estímulo inteiro. Em outras palavras, temos o rótulo de um neurônio qualquer como a saída desejada de um estímulo específico quando esse neurônio estiver representando-o.

Assim, para um conjunto de treinamento $\psi = \{(y_i^d, x_i)\}_{i=1}^n$, onde os x_i são as entradas, o rótulo do neurônio j, R_j , satisfeitos os critérios do algoritmo de aprendizado, pode ser dado como :

$$R_j = y_i^d \quad (11)$$

3.3.6 Dinâmica do Aprendizado

Basicamente, a dinâmica da rede ARC compreende dois momentos distintos: a fase de aprendizado e a fase de reconhecimento. Durante a fase de aprendizado, a rede aprende (assimila) os fatos que são submetidos à ela. A assimilação dos fatos é realizada através de um processo de ajuste das conexões sinápticas dos neurônios e sua respectiva rotulação com o nome dos fatos aprendidos. A fase de reconhecimento é mais simples, sendo responsável apenas em retornar o rótulo do neurônio selecionado frente a um estímulo qualquer presente na camada de entrada. Esta segunda fase não possui ajuste e nem rotulação.

Para realizar o aprendizado, a rede precisa determinar qual neurônio terá seus pesos ajustados em relação ao fato apresentado, e então a respectiva rotulagem. O procedimento para determinar o neurônio tido como “vencedor” é baseado na distância euclidiana entre o vetor de entrada \mathbf{x}_i e o vetor de pesos \mathbf{w}_{ji} de cada neurônio. Se utilizarmos o índice $ind(x)$ para identificar o neurônio que possui o melhor resultado em relação ao vetor de entrada \mathbf{x} , podemos determinar $ind(x)$ aplicando a seguinte condição:

$$ind(x) = \min_j \{ \|\mathbf{x}_i - \mathbf{w}_{ji}\| \}, \text{ com } j = 1, 2, \dots, N \quad (12)$$

onde N = quantidade de neurônios na rede

Depois de realizada a distância euclidiana de todos os neurônios, temos o neurônio $ind(x)$ como o centro de atenção, chamado de neurônio “vencedor” para o vetor de entrada \mathbf{x}_i . Os pesos do neurônio “vencedor” deverão ser ajustados em relação ao fato apresentado (vetor de entrada \mathbf{x}_i). O ajuste é realizado através da taxa de aprendizado, dado como α ($0 < \alpha < 1$).

$$\mathbf{w}_{ind(x)}^{t+1} = \mathbf{w}_{ind(x)}^t + \alpha \cdot [\mathbf{x}_i - \mathbf{w}_{ind(x)}^t] \quad (13)$$

onde : t = instante t no tempo

$ind(x)$ = neurônio “vencedor”

α = taxa de aprendizado

\mathbf{x}_i = i -ésima entrada

$\mathbf{w}_{ind(x)}$ = pesos do neurônio $ind(x)$

Da mesma forma, o rótulo do neurônio $ind(x)$ deve ter o rótulo correspondente da entrada x_i , ou seja $R_j = y_i^d$. Outro procedimento realizado neste momento é a expansão cortical, que é a criação de novos neurônios na camada de saída sem afetar as características dos neurônios já constituídos. Esta expansão ocorre quando o rótulo do não confere com a saída desejada. A medida de expansão da rede é tomada pelo raio de vizinhança partindo do neurônio $ind(x)$, assim, os novos limites da quantidade de linhas e colunas da rede neural se definem pela soma do raio de vizinhança à linha e coluna do neurônio “vencedor” :

1) Definição da expansão de linhas de neurônios:

$$LLR = \begin{cases} LN_{ind(x)} + V & LN_{ind(x)} + V > LLR \\ LLR & LN_{ind(x)} + V \leq LLR \end{cases} \quad (14)$$

onde : LLR = Limite de linhas da rede neural

$LN_{ind(x)}$ = Linha do neurônio $ind(x)$

V = Raio de vizinhança

2) Definição da expansão de colunas de neurônios:

$$LCR = \begin{cases} CN_{ind(x)} + V & CN_{ind(x)} + V > LCR(t) \\ LCR & CN_{ind(x)} + V \leq LCR(t) \end{cases} \quad (15)$$

onde : LCR = Limite de colunas da rede neural

$CN_{ind(x)}$ = Coluna do neurônio $ind(x)$

V = Raio de vizinhança

3.3.7 Ajuste Sináptico da Vizinhança

Procurando seguir o modelo biológico, os neurônios vizinhos ao neurônio vencedor também são ajustados dentro de um senso físico. O critério de vizinhança é definido por um raio que tem como centro o neurônio $ind(x)$. Esse raio é denotado por $V_{ind(x)}$.




Figura 28 – Exemplo de raio para vizinhança igual a 2

O ajuste dos neurônios vizinhos ao neurônio $ind(x)$ é realizado seguindo uma alteração do valor de α conforme a distância do neurônio ajustado (dentro do raio da vizinhança) em relação ao neurônio $ind(x)$. Ou seja, quanto mais distante o neurônio ajustado do neurônio $ind(x)$, menor será a parcela de ajuste dos pesos, provocando assim um decréscimo linear seguindo a idéia de perda da força a medida que se distancia do epicentro:

$$\alpha(t+1) = \alpha(t) - \frac{\eta(t)}{V_{ind(x)}} \quad (16)$$

onde : t = Instante t no tempo

α = Taxa de aprendizado

η = Raio de ajuste

$V_{ind(x)}$ = Raio de vizinhança da rede neural para o neurônio $ind(x)$

Outras formas de adaptação de pesos α também podem ser utilizadas, como é o caso de um valor estático em α , atingindo toda a vizinhança de forma uniforme, ou ainda, utilizando uma variação exponencial. Enfim, esse tipo de critério também é flexível e pode ser alterado conforme a aplicação.

Outro critério necessário para o ajuste dos neurônios vizinhos ao neurônio $ind(x)$ é a ausência de rótulo do neurônio vizinho analisado no momento. Ou seja, os neurônios que já possuem rótulo, mesmo pertencendo à $V_{ind(x)}$, não devem ser ajustados.

$$\mathbf{w}_j^{(t+1)} = \begin{cases} \mathbf{w}_j^t + \alpha(t) \cdot [\mathbf{x}_i - \mathbf{w}_j^t] & j \in V_{ind(x)}, R_j = \phi \\ \mathbf{w}_j^t & j \notin V_{ind(x)}, R_j \neq \phi \end{cases} \quad (17)$$

onde : t = instante t no tempo

$ind(x)$ = neurônio “vencedor”

α = taxa de aprendizado

x_i = i -ésima entrada

w_j^t = pesos do neurônio j no tempo t

R_j = rótulo do neurônio j

ϕ = ausência de rótulo

Após realizado o ajuste dos neurônios compreendidos em $V_{ind(x)}$, segue-se o procedimento de rotulagem desses neurônios, e o critério adotado para rotulá-los, ou não, com o rótulo do estímulo apresentado (entrada x_i), é através da medida fornecida pelo δ de cada neurônio, conseguido após o cálculo da distância euclidiana. Por exemplo, todo o neurônio que obtiver um δ maior que 55%, frente a um determinado estímulo, se encontra apto a representá-lo, e assim recebe o rótulo correspondente. Os neurônios cujo δ não alcançam 55% não são rotulados, e assim não assimilam o estímulo presente na camada de entrada da rede neural.

$$R_j = \begin{cases} R_x & j \in V_{ind(x)}, \delta_j > 55\% \\ R_j & j \notin V_{ind(x)} \end{cases} \quad (18)$$

onde : R_j = rótulo do neurônio j

R_x = rótulo da entrada x_i , ou seja y_i^d

$V_{ind(x)}$ = raio de vizinhança em torno do neurônio $ind(x)$

δ_j = força e potencial de ação do neurônio j

O valor de 55% para o δ é móvel, podendo ser maior ou menor conforme as necessidades do projetista da rede neural.

3.4 Software Desenvolvido

3.4.1 Plataforma e Ambiente de Desenvolvimento

As técnicas de pré-processamento foram combinadas com a rede neural ARC em um software desenvolvido especificamente para este fim, o reconhecimento automático das fases do sono. Por conveniências diversas adotou-se, como plataforma de desenvolvimento, um computador baseado na tecnologia IBM-PC (Pentium II 300 MHz) rodando o sistema operacional Windows 98.

O software para as simulações foi desenvolvido utilizando-se o ambiente de programação Delphi 4.0 e a linguagem Object Pascal. O sistema também foi montado dentro da filosofia da orientação a objetos, procurando seguir um paradigma de desenvolvimento que facilitasse alterações e testes.

3.4.2 Um Pouco Sobre os Objetos

O sistema de reconhecimento, chamado de IndexArc, foi modelado de forma orientada a objetos resultando em um estrutura onde o sistema é composto por três objetos principais, são eles: ARC, Processamento e Gerenciador




Figura 29 – Estrutura Todo-Parte dos objetos do IndexArc

O objeto Gerenciador é quem coordenada a troca de mensagens entre os objetos Processamento e ARC, uma vez que esses dois objetos apenas respondem com transformação de informações (tratamento dos dados) e reconhecimento de padrões, respectivamente.

Essa troca de mensagens entre os objetos, basicamente, obedece dois momentos distintos, o treinamento e o reconhecimento. Durante o momento de treinamento, a troca de mensagens pode ser vista como o repasse do *senal original* (captado do EEG) do objeto Gerenciador para o objeto Processamento. Este sinal, então devidamente tratado pelo objeto Processamento, chamado neste momento de *senal processado*, retornará para o Gerenciador. O Gerenciador somará, ao *senal processado*, informações necessárias para o treinamento, e o repassará como mensagem para o objeto ARC. Feito isso, o Gerenciador envia a mensagem de *aprender* para o objeto ARC.




Figura 30 – Troca de mensagens durante o treinamento

Durante o momento do reconhecimento, a troca de mensagens também abrange o repasse do *senal original* do objeto Gerenciador para o objeto Processamento. Tendo recebido de volta o *senal processado* do objeto Processamento, o Gerenciador o repassará como mensagem para o objeto ARC. Feito isso, o Gerenciador envia uma mensagem ao objeto ARC solicitando a tarefa do reconhecimento do padrão. Respondendo à solicitação, o objeto ARC retornará o sinal classificado conforme o seu conhecimento adquirido durante a fase de treinamento.

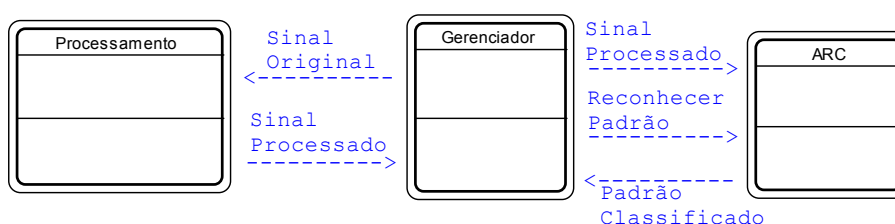


Figura 31 - Troca de mensagens durante o reconhecimento

3.4.3 O Protótipo IndexArc

O sistema IndexArc está dividido em diversas tarefas de operação, que por sua vez estão separadas em 5 diferentes painéis. Os painéis 1, 3 e 5 ilustram o funcionamento do protótipo desenvolvido. Os painéis 2 e 4 são utilizados como teste e calibragem de sinais. O primeiro painel, chamado de *Arquivo*, é onde o sistema realiza a conversão do

formato Poliwin¹⁴ do arquivo de exame para um formato próprio, desenvolvido para este fim.




Figura 32 – Painel de conversão de arquivos

Essa conversão é realizada com o objetivo de reduzir o tamanho do arquivo, uma vez que o sistema proposto utiliza somente um canal de sinal, enquanto que o sistema Poliwin utiliza até 32 canais diferentes. Antes de realizar a operação de conversão, pode-se escolher qual dos canais de EEG (registrados pelo Poliwin) que será utilizado para compor o novo arquivo. É neste painel também que escolhe-se qual o exame que será manuseado no painel chamado *Labels*.

O quinto painel, *Labels*, possui duas tarefas bastante distintas. Uma delas é gerar o arquivo de índices partindo do arquivo reduzido resultante do painel *Arquivo*, e a outra é a realização do treinamento e do reconhecimento utilizando o arquivo de índices gerado. Essa separação de tarefas permite que os índices sejam gerados com segmentos de diferentes tamanhos (quantidades de pontos) para diferentes tipos de testes.

¹⁴ Formato de propriedade da empresa EMSA – Equipamentos Médicos S.A.

The screenshot shows a software window titled "Form1" with a menu bar containing "Arquivo", "Treinamento Artur", "Resultados", "Índice", and "Labels". The main panel is divided into several sections:

- On the left, there is a checkbox labeled "Gerar MATLAB". Below it are two input fields: "Qt de Pontos" with the value "10" and "Qt de Características" with the value "20". A button labeled "Gerar Índices" is positioned below these fields.
- In the center, there are two more input fields: "Tamanho do Pixel (seg)" with the value "30" and "Qt de Características" with the value "20".
- To the right of these fields are two buttons: "Treinar ARC" and "Testar ARC".
- Further to the right are two checkboxes: "Gerar Treino para Matlab" and "Gerar Teste para Matlab".

At the bottom of the window, there is a "Título" field, a "Tempo de Execução" field, and two buttons: "Congelar" and "Fechar".

Figura 33 - Painel de operações

Outro pré-processamento que pode sofrer interferências neste painel é a extração de características de segmentos do arquivo de índices. O tamanho desses segmentos do arquivo de índices também é configurável nesse mesmo painel. Uma vez treinada a rede neural ARC, esta pode ser testada com qualquer outro exame selecionado no painel *Arquivo*.

Finalmente, no painel 3, é onde pode-se visualizar o resultado das operações de treinamento e reconhecimento executadas no painel *Labels*. Este painel apenas apresenta resultados e algumas simples estatísticas como forma de orientar o treinamento da rede neural. O painel também permite que sejam gerados arquivos com os resultados obtidos para serem manuseados em outros ambientes.

Form1

Arquivo | Treinamento Artur | Resultados | Índice | Labels

Pixel	Sistema	Sistema	Médico
1	0	0	0
2	0	0	0
3	0	0	0
4	0	0	0
5	0	0	0
6	0	0	0
7	0	0	0
8	0	0	0
9	0	0	0
10	1	1	3
11	1	1	3
12	1	1	3
13	1	1	3
14	1	1	3
15	1	1	3

Paciente : PLG0006501

CLASSE Acertos / Total = %

0	13 / 15 = 86.67
1	49 / 49 = 100.00
2	0 / 1 = 0.00
3	97 / 175 = 55.43
4	207 / 227 = 91.19

ACERTOS = 366 / TOTAL = 466
 Percentual de Acerto = 78.541

Transportar para MATLAB Inverter

Testando com Labels

00:00:09

Congelar Fechar

Figura 34 - Painel de resultados

4 A Aplicação

4.1 Considerações Iniciais

Para os testes devidos, foi utilizado o canal C3 do EEG dos exames de 4 pacientes adultos do sexo masculino fornecidos pela empresa EMSA¹⁵. Os exames foram estagiados manualmente por profissionais da área de saúde ligados à empresa. Os exames fornecidos foram assim denominados :

Tabela 4 – Pacientes usados para o trabalho

Paciente	Idade	Tempo de Registro (horas)
6501	48	03:53:05
7706	25	05:47:58
6740	25	07:35:43
9300	31	07:36:40

Para a realização dos mesmos, modificou-se a quantidade de classes (estágios, rem e acordado) do estagiamento automático. A modificação abrange, basicamente, os estágios 3, 4 e 1. Os estágios 3 e 4 foram agrupados em um único estágio, chamado de estágio 3. Essa decisão foi tomada uma vez que ambos os estágios (3 e 4) são bem definidos em relação ao resto do grupo e sua diferenciação não é relevante para o estudo em questão. O estágio 1 foi somado junto ao estágio 2. Essa decisão foi tomada em relação à pouca presença deste estágio (1% a 5%) em relação ao tempo total do sono.

4.2 Tratamento dos Dados Coletados

Para a construção dos vetores de treinamento e de testes, seguiram-se as fases do pré-processamento, onde para a primeira fase utilizou-se os limites inferiores e superiores em -1000 e +1000, respectivamente. Para a gerar o vetor de índices, utilizou-

¹⁵ O software POLIWIN, já citado neste trabalho, foi desenvolvido pela empresa EMSA – Equipamentos Médicos S.A.

se a recursão a cada 10 pontos em todo o sinal original e, finalmente, o vetor de características (treinamento ou teste) é gerado em intervalos regulares de 30 segundos, ou 600 pontos do vetor de índices. O tempo de 30 segundos, também chamado de época, foi adotado em função das anotações médicas observadas (GUIOT, 1996).

A quantidade de características extraídas (faixas de amplitudes) para cada época utilizadas nesse trabalho foi de 20 faixas. Essa quantidade de faixas, embora possa ser variável, foi conseguida depois de sucessivos experimentos controlados, que demonstraram que as 20 faixas apresentam maior estabilidade para o sistema de estagiamento.

4.3 Treinamento da Rede Neural

A rede neural foi treinada utilizando apenas um exame, sendo que os demais exames constituíram os testes para o sistema. Para o treinamento, utilizou-se quantidades diferenciadas das classes “acordado”, “REM”, e dos outros 2 estágios (1/2 e 3/4), pois depende da quantidade de ocorrência de cada classe no exame utilizado.

4.4 Resultados Obtidos

4.4.1 Testes com Treinamento do Paciente 6501

A rede neural ARC foi treinada utilizando 15 amostras para a classe “acordado”, 49 para a classe “REM”, 50 amostras para o estágio 2 e 50 amostras para o estágio 3.




Figura 35 – Distribuição dos Neurônios Treinados por Classe

O exame do paciente 7706, submetido à análise da rede neural treinada com o exame do paciente 6501, obteve uma taxa de acerto de 76,54 % confrontado com o resultado do estagiamento realizado de forma manual. A simulação¹⁶ segue a seguinte distribuição:

Tabela 5 – Distribuição do Acerto para o Paciente 7706

Classe	Automático	Manual	Acerto (%)
Acordado	0	13	0
REM	71	146	48,63
Estágio ½	290	355	81,69
Estágio ¾	171	181	94,48
Total	532	695	76,54

O hipnograma com a apresentação simultânea do resultado do estagiamento automático (sistema) mais o estagiamento manual (médico), também revela a consonância dos resultados obtidos em relação à sua disposição espacial no tempo, ou seja, os resultados conseguidos são contados levando-se em conta também o tempo em que ambos os resultados coincidem. Essa disposição pode ser melhor observada na Figura 36.

¹⁶ Esses resultados foram conseguidos em 1m12s em um computador tipo pentium II de 200 MHZ.





Figura 36 – Hipnograma do paciente 7706

Outra representação gráfica que é bastante útil é o histograma por classe, que apresenta a quantidade de tempo de cada classe por método (automático e manual).



Para os outros dois exames, 6740 e 9300, pode-se observar os seguintes resultados, também obtidos usando as mesmas configurações neurais aplicadas ao exame 7706 :

Tabela 6 – Distribuição do Acerto para os Pacientes 6740 e 9300

Classe	6740			9300		
	Automático	Manual	Acerto (%)	Automático	Manual	Acerto (%)
Acordado	1	95	1,05	4	79	5,06
REM	32	66	48,48	122	232	52,59
Estágio 1/2	515	659	78,15	321	409	78,48
Estágio 3/4	89	91	97,80	111	193	57,51
Total	637	911	69,92	558	913	61,11


4.4.2 Testes com Treinamento do Paciente 6740

Para outra experimentação, tomamos o paciente 6740 como suporte de treinamento para a rede neural. Submetendo o exame do paciente 7706 à análise da rede neural, confrontado com o resultado do estagiamento realizado de forma manual, a taxa de acerto foi de 62,01 %. A simulação segue a seguinte distribuição:

Tabela 7 – Distribuição do Acerto para o Paciente 7706

Classe	Automático	Manual	Acerto (%)
Acordado	0	13	0
REM	27	146	18.49
Estágio 1/2	265	355	74.65
Estágio 3/4	139	181	76.80
Total	431	695	62.01

Esses resultados, quando visualizados em um histograma por classe, apresentando a quantidade de tempo de cada classe por método (automático e manual), possuem a seguinte representação :



Para os outros dois exames, 6501 e 9300, podem-se observar os seguintes resultados, também obtidos usando as mesmas configurações neurais aplicadas ao exame 7706 :

Tabela 8 – Distribuição do Acerto para os Pacientes 6501 e 9300

Classe	6501			9300		
	Automático	Manual	Acerto (%)	Automático	Manual	Acerto (%)
Acordado	3	15	20	8	79	10.13
REM	38	49	77.55	125	232	53.88
Estágio 1/2	59	175	33.71	272	409	66.50
Estágio 3/4	184	227	81.06	145	193	75.13
Total	284	466	60,94	550	913	60,24

4.4.3 Análise dos Resultados

Os resultados demonstram que a taxa de acerto para o estágio 3/4 é alta em todos os exames, em contrapartida com a classe acordado, cuja detecção é um tanto difícil para o sistema. O reflexo do percentual de acerto parece depender da quantidade de ocorrências da fase durante o treinamento da rede.

Todavia, a distribuição apresentada pelos gráficos 01 e 02, comparando o estagiamento manual com o automático, relata que o estagiamento automático está em consonância com os tempos de sono apresentados por um jovem adulto. Esses tempos podem ser verificados na seção 2.5 *Generalidades Sobre o Sono Normal*.

Vale ressaltar que o hipnograma (Figura 36) apresenta uma distribuição no tempo revelando grande harmonia dos resultados obtidos em relação à sua disposição espacial no tempo.

Outro ponto importantes dos resultados obtidos, é com referência à velocidade na qual esses mesmos resultados foram conseguidos. A rede neural mostrou-se bastante veloz, tanto para o treinamento, quanto para os testes realizados.

5 Conclusões e Recomendações

5.1 Conclusões

Os resultados alcançados no presente trabalho apontam para uma possibilidade real de realizar o reconhecimento automático do sono através do uso de processamento de sinal e inteligência artificial (como foi o caso da utilização da rede neural artificial), uma vez que o sistema proposto portou-se de forma adequada durante os testes realizados.

Num primeiro momento, como vantagens da automatização desse processo, pode-se citar a rapidez do estagiamento automático em relação ao estagiamento manual. O estagiamento automático consome até 5 minutos de tempo máquina, enquanto que o método manual pode consumir uma média de 3 horas. Entretanto, um outro fator de grande relevância é a qualidade do estagiamento conseguida em função da regularidade de um sistema automático. O método manual tende a ser cansativo e tedioso, provocando uma qualidade variável ao longo do estagiamento, enquanto que um sistema automático garante o mesmo desempenho durante todo o processo.

Também verificou-se a importância do processamento do sinal digital como forma de melhorar a sua representatividade. Técnicas como o “Corte do Sinal Digital” demonstram que esses sinais estão carregados de ruídos, e que portanto, todo e qualquer esforço nesse sentido pode atenuar "impurezas" que tende a serem fatais em um sistema de reconhecimento. Outro ponto positivo é a combinação da técnica “Geração dos Índices Recursivos” antecedendo a “Extração de Características”, que também apresentou eficácia satisfatória.

A rede utilizada, embora não tenha recebido um tratamento específico para este problema, apresentou resultados que indicam a sua eficácia em problemas de reconhecimento de padrões.

Finalmente, um ponto de relevância que deve ser citado é a questão da utilização de apenas um canal de EEG para efetuar o estagiamento automático. Essa proposta da utilização de um canal, revela que um único canal pode não ser suficiente para um estagiamento completo e adequado, considerando as normas médicas vigentes. No entanto, esse trabalho explorando apenas o canal C3 mostra que este possui grande representatividade, confirmando as observações citadas por CARSKADON e RECHTSCHAFFEN (1994), onde os mesmos argumentam que as ondas usadas para distinguir os estágios são bem visualizadas utilizando esse canal.

5.2 Recomendações

Como objeto de estudos futuros, recomendamos a utilização de múltiplos canais de EEG, bem como a utilização de outros canais não explorados neste trabalho para a detecção do estágio REM. Vale também, a utilização de outras funções para a obtenção do vetor de índices, além de explorar outras formas de extração do vetor de características. Finalmente, a utilização de outros modelos de arquiteturas de aprendizagem de redes neurais pode trazer novos resultados.

Vale também ressaltar que a utilização de tecnologias de pré-processamento de sinal digital, combinadas com redes neurais artificiais demonstram resultados favoráveis à investigações mais profundas. Para o caso do pré-processamento, ressalta-se a eficácia da técnica da extração de características, merecendo também estudos mais específicos.

Cabe também estudos específicos para detecção de cada classe separadamente utilizando tantos canais quantos forem necessários. Ou seja, sugere-se a utilização de técnicas específicas para detecção de classes específicas. Esse procedimento pode trazer resultados uma vez que cada classe apresenta características relativamente distintas, o que uma única técnica pode não abranger.

Finalmente, também indicamos outros estudos e aplicações da rede neural ARC uma vez que esta demonstrou resultados estimuladores, além de rapidez de processamento e treinamento. Outros aspectos da rede neural ARC também podem vir a ser úteis em determinadas aplicações, como é o caso da sua imunidade à perda de neurônios.

6 Referências Bibliográficas

1. ASERINK, E. e KLEITMAN, N. .Regular periods of eye mobility and concomitant phenomena during sleep. Science, n. 118, 1953.
2. BAUMGART-SCHMITT, R., HERRMANN, W. M., EILERS, R. e BES, F. .Application of Evolutionary and Genetic Algorithms to Reduce the Feature Space and to Develop Classification Rules. Neuropsychobiology, v. 36, p. 194-210, 1997.
3. BAUMGART-SCHMITT, R., HERRMANN, W. M., EILERS, R. e BES, F. .Application of Evolutionary and Genetic Algorithms to Reduce the Feature Space and to Develop Classification Rules. Neuropsychobiology, v. 37, p. 49-58, 1998.
4. BERTHOMER, C., PRADO, J. e BENOIT, O. .EEG Analysis Using Non-Uniform Oversampled Filter Banks. Biomedical Sciences Instrumentation, v. 34, p. 119-124, 1997.
5. BIANCO, Margarida. Classificação dos distúrbios do sono. In : REIMÃO, Rubens. Sono : Estudo Abrangente. 2. Ed. São Paulo : Atheneu, 1996.
6. BURGER, D. CANTANI, P e WEST, J. Multidimensional Analysis of Sleep Electrophysiological Signal. Biology Cybernetics. V. 26, p. 131-139, 1977.
7. CARSKADON, Mary A. e DEMENT, William. Normal Human Sleep : Na Overview. In : KRYGER, Meir, ROTH, Thomas e DEMENT, William. Principles and Practice of Sleep Medicine. 2. Ed. USA : W. B. Saunders Company, 1994.
8. CARSKADON, Mary A. e RECHTSCHAFFEN, Allan. Monitoring and Staging Human Sleep. In : KRYGER, Meir, ROTH, Thomas e DEMENT, William. Principles and Practice of Sleep Medicine. 2. Ed. USA : W. B. Saunders Company, 1994.
9. DEGROOT, Jack. Neuroanatomia. ed. 21. Rio de Janeiro : Guanabara, 1994.
10. EMSA – Equipamentos Médicos S/A. EMSA. 1998. <http://www.emsamed.com.br> (15 de Outubro de 1998).

11. FARINA JR, Paulo Danilo. Entrevista Concedida pelo Diretor Executivo da EMSA Equipamentos Médicos S/A. Rio de Janeiro, 15 out. 1998.
12. FUSTER, J. Network memory. Trends In Neuroscience, v. 20, n. 10, p. 451-459, 1997.
13. GAILLARD, J. M., TISSOT, R. .Principles of automatic analysis of sleep records with a hibrid system. Biomedical Computation. V. 6, p. 1-13, 1973.
14. GREEN, David Alan. A Hybrid Preprocessor for Sleep Staging Using the EEG. Ottawa, 1975. Dissertação (M.Eng.). Department of Systems and Computer Engineering, CARLETON University.
15. GUIOT, Marilene. Polissonografia. In : REIMÃO, Rubens. Sono : Estudo Abrangente. 2. Ed. São Paulo : Atheneu, 1996.
16. GUYTON, Arthur. Neurociências Básica. 2. Ed. .Rio de Janeiro : Guanabara, 1993.
17. HADJIYANNKIS, K. et alii .FFT analysis of EEG during stage2-to-REM transitions in narcoleptic patients and normal sleepers. Electroencephalography and Clinical Neurophysiology, v. 103, p. 543-553, 1997.
18. HAYKIN, Simon. Neural Netwoks : a comprehensive foundation. USA : Macmillan College Publishing, 1994.
19. JUDEX SYSTEMS. <http://www.judex.dk> (09 de Setembro de 1998).
20. KARACAN, I. e SHAPIRO, A. .Erection cycle during sleep in relation to dream anxiety. Archive Genital Psychiatric, n. 15, 1966.
21. KUFRIN, R. . Parallel C4.5 Rule Generator - Benchmarks. 1997.
<http://www.ncsa.uiuc.edu/People/rkufrin/projects/HPML/c4.5rules.html> (10 de Setembro de 1998).
22. LANGLEY, P. e SIMON, H. .Applications of Machine Learning and Rule Induction. In : Proceedings of the Fourteenth National Conference on Artificial Intelligence. (AAAI'97). Anais... Providence, 1997.
23. LOESCH, Cláudio e SARI, Solange T. .Redes Neurais Artificiais : Fundamentos e Modelos. Blumenau : FURB, 1996.
24. LOSSMANN, Erik . EEG-based sleep stage scoring using wavelet transform and artificial neural network. In : Procedings of the post-graduate student seminar. Anais... Tallinn Technical University, 1996.
25. LOSSMANN, Erik. Computerized Sleep Stage Scoring. 1997.
<http://crnet4.carelian.fi/euromed/sss/sss.html> (09 de Setembro de 1998).

26. MARTINEZ, Denis. O Sono. 1996. <http://www.vanet.com.br/doctor/sono.htm> (08 de Setembro de 1998)
27. MEDICAL Knowledge Based Systems. 1996.
http://www.vision.auc.dk/Forskning_eval/Chapter_4_final.html (09 de Setembro de 1998).
28. NIELSEN, K. D. et alii. Causal Probabilistic and power spectral estimation used in sleep stage classification. Methods of Information in Medicine, v. 36, p. 345-348, 1997.
29. POHL, V. e FAHR, E. Neuro-Fuzzy Recognition of K-Complexes in Sleep EEG Signals. 1995. http://funsan.biomed.mcgill.ca/~funnel/embc95_cd/texts/058.htm (11 de Setembro de 1998).
30. POLIWIN.HLP. Manual de Operação do PoliWin. EMSA. Rio de Janeiro, 25 de março de 1998.
31. PRINCIPE, J e TOME A. Performance and training strategies in feedforward neural networks: an application to sleep staging. In : Proceeding of the International Joint Conference on Neural Networks (IJCNN'89). Anais...Washington, USA, v. 1, p. 341-346, 1989.
32. PRINCIPE, Jose, CHANG, Tae-Gyu, GALA, Sunit e TOME, Ana. Informaion Processing Models for Sleep Staging. Expert Systems with Applications. V. 6, p. 399-409, 1993.
33. QUARTZ, Steven. Neural networks, nativism, and the plausibility of constructivism. Cognition, v. 48, p. 223-242, 1993.
34. RAY, S. R. LEE, W. D., MORGAN, C. D. Computer sleep stage scoring – an expert system approach. Biomedical Computation. V. 19, p. 43-61, 1986.
35. RECHTSCHAFFEN, A. e KALES, A. Manual of Standardized Terminology : Techniques and Scoring System for Sleep Stages of Human Subjects. Los Angeles : Brain Research Institute, 1968.
36. SCHALTENBRAND, N. et alii. Sleep Scoring Using the Neural Network Model : Comparison Between Visual and Automatic Analysis in Normal Subjects and Patients. Journal Sleep, v. 19, 1995.
37. SCHAUF, Charles, MOFFET, David, MOFFET, Stacia. Fisiologia Humana. Rio de Janeiro: Guanabara, 1993.

38. SHIMADA, Takamasa e SHIINA Tsuyoshi. Detection of Characteristic Waves of Sleep EEG by Neural Network Analysis. 1997. <http://www.milab.is.tsukuba.ac.jp/~shimada/> (12 de Setembro de 1998).
39. SONNINO, Bruno. Entrevista Concedida pelo Chefe do Desenvolvimento do PolyDream da EMSA Equipamentos Médicos S/A. Rio de Janeiro, 17 out. 1998.
40. SOUZA, João Artur. Reconhecimento de padrões usando indexação recursiva. Exame de Qualificação. PPGE, UFSC, 1998.
41. SYKACEK, P. , DORFFNER, G., RAPPELSBERGER, P. e ZEITLHOFER, J. . Austrian Research Institute for Artificial Intelligence [Viena]. Evaluating confidence measures in a neural network based sleep stager. Austria, 1997.
42. SYKACEK, P. , DORFFNER, G., RAPPELSBERGER, P. e ZEITLHOFER, J. . Experiences with bayesian learning in a real world application. Advances in Neural Information Processing Systems, v. 10, 1998.
43. TAFNER, Malcon e BARCIA, Ricardo M. . Reconhecimento de voz utilizando redes neurais artificiais. Pesquisa Operacional. v.15, n.1 e 2, p 117-136, jun./dez. 1996.
44. TAFNER, Malcon, XEREZ, Marcos e RODRIGUES FILHO, Ilson W.. Redes Neurais Artificiais : Introdução e princípios de neurocomputação. Blumenau : EKO, 1995.
45. TAFNER, Malcon. La Plasticidad Neuronal Artificial. RAN – Revista Argentina de Neurociencias. Argentina – Buenos Aires, v.2, n.4, p50-53, ago. 1998.
46. TAFNER, Malcon. Reconhecimento de palavras faladas isoladas usando redes neurais artificiais. Florianópolis, 1996. 102 f. Dissertação (Mestrado em Engenharia de Produção). Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina.
47. TANKOVA, Iren e BUELA-CASAL, Gualberto. Sono e envelhecimento. In : REIMÃO, Rubens. Sono : Estudo Abrangente. 2. Ed. São Paulo : Atheneu, 1996.
48. VELLUTI, Ricardo. Fisiologia do sono. In : REIMÃO, Rubens. Sono : Estudo Abrangente. 2. Ed. São Paulo : Atheneu, 1996.