

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

**MAPA FAN NO ESTAGIAMENTO AUTOMÁTICO DO
SONO**

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

GERTRUDES APARECIDA DANDOLINI

**FLORIANÓPOLIS
2000**

GERTRUDES APARECIDA DANDOLINI**MAPA FAN NO ESTAGIAMENTO AUTOMÁTICO DO
SONO**

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

Prof. Ricardo Miranda Barcia, PhD.
Coordenador do Curso

BANCA EXAMINADORA:

PROF. ALEJANDRO MARTINS R., DR.
ORIENTADOR

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

PROF^a. ELIZABETH S. SPECIALSKI, DR^a.
MODERADORA

PROF. ROBERTO C. S. PACHECO, DR.

PROF. CELSO A. ALVES KAESTNER, DR.
EXAMINADOR EXTERNO

PROF. MALCON A. TAFNER, DR.
EXAMINADOR EXTERNO

Florianópolis, 6 de setembro de 2000.

*“Começar fazendo o necessário,
depois o possível e
de repente você estará fazendo o impossível.”*

(São Francisco de Assis)

Para JOÃO ARTUR e HEITOR
Aos meus Pais

Agradecimentos

A todos que direta ou indiretamente contribuíram para que eu pudesse realizar este trabalho.

A CAPES pelo apoio financeiro.

À Universidade Federal de Pelotas, pela liberação de minhas atividades acadêmicas para realização deste Doutorado.

À Universidade Federal de Santa Catarina, em especial ao Programa de Pós-Graduação em Engenharia de Produção em nome do Prof. Ricardo Miranda Barcia, por ter me recebido de braços abertos.

À empresa EMSA pelo fornecimento de informações e dos registros polissonográficos.

A todos os meus professores, com os quais muito eu aprendi e entendi ...

Aos professores membros da banca examinadora pela avaliação e contribuição para o aperfeiçoamento deste trabalho.

Ao professor e Orientador Alejandro Martins Rodriguez, pela orientação, incentivo e confiança recebidos durante a execução deste trabalho.

À Prof^a. Edis Mafra Lapolli, pelo seu incentivo, por sua energia e alegria.

A todos os colegas, em especial ao Roberto Raittz e Malcon Tafner pelos momentos de discussões, pela colaboração e apoio.

Aos meus pais, Romeu e Adulce, que com dedicação e amor, me educaram e mostraram como trilhar meus próprios caminhos.

E um agradecimento todo especial, ao JOÃO ARTUR e HEITOR que sempre souberam estar do meu lado, sofrendo ou vibrando comigo...

Aos amigos que sabem ser amigos ...

E finalmente, a ELE que torna tudo possível ...

SUMÁRIO

<i>Lista de Figuras</i>	<i>IX</i>
<i>Lista de Tabelas</i>	<i>XI</i>
<i>Lista de Quadros</i>	<i>XII</i>
<i>Lista de Gráficos</i>	<i>XIII</i>
<i>Resumo</i>	<i>XIV</i>
<i>Abstract</i>	<i>XV</i>
1 Introdução	1
1.1 Origem do trabalho	1
1.1.1 Processamento de Sinais	1
1.1.2 O sono e os sinais biológicos	2
1.2 Justificativas	5
1.3 Objetivos do Trabalho	7
1.3.1 Objetivo Geral	7
1.3.2 Objetivos Específicos	7
1.4 Metodologia de desenvolvimento da Pesquisa	8
1.5 Estrutura do Trabalho	9
2 O Sono	10
2.1 Introdução	10
2.2 Evolução	11
2.3 A polissonografia	15
2.3.1 Registros.....	17
2.3.2 As perspectivas futuras	20
2.4 As Fases e a Estrutura do Sono	21
2.4.1 As fases do Sono.....	23
2.4.2 Progresso do Sono Durante a Noite.....	26
2.4.3 O Hipnograma	29
2.5 Os Distúrbios do Sono	29
2.6 O estagiamento	31
2.6.1 As Dificuldades do Estagiamento.....	32
2.6.2 Estagiadores do Sono.....	33
2.7 O Mercado	35
2.8 Conclusão	37
3 Processamento de Sinal Digital	39
3.1 Introdução	39
3.2 Sinal Digital e o Processamento	41

3.3	Vantagens e Desvantagens do DSP	42
3.4	Evolução	43
3.5	Áreas de Aplicação	45
3.6	Elementos em DSP	46
3.7	Operações Chaves em DSP	48
3.7.1	Convolução.....	48
3.7.2	Correlação	50
3.7.3	Filtros Digitais	52
3.7.4	Transformadas Discretas.....	53
3.7.5	Modulação	54
3.8	A estatística e a probabilidade.....	55
3.9	O DSP em Sinais Biológicos.....	56
3.10	Conclusões.....	58
4	<i>Transformadas e Filtros Digitais.....</i>	<i>61</i>
4.1	Transformadas.....	61
4.1.1	Transformada de Fourier.....	62
4.1.2	Transformada Wavelets	65
4.2	Filtros	68
4.2.1	Exemplos de Filtros Digitais Simples.....	70
4.2.2	Tipos de filtros Digitais: Recursivos e Não Recursivos	72
4.2.3	Ordem de um filtro digital.....	73
4.2.4	Coefficientes dos filtros digitais	73
4.2.5	Vantagens e desvantagens dos filtros FIR e IIR.....	75
4.2.6	Filtros Adaptativos.....	76
4.3	Conclusão	80
5	<i>Modelo Proposto: O Sistema Mapa FAN</i>	<i>82</i>
5.1	Introdução.....	82
5.2	Arquitetura	84
5.3	Pré-Processamento: Ordenação	85
5.3.1	Teoria da Informação	86
5.3.2	Ordenação	87
5.4	O classificador Mapa FAN	89
5.4.1	FAN	89
5.4.2	O Mapa FAN.....	91
5.5	Mapa FAN x FAN.....	94
5.6	Conclusões.....	95
6	<i>Estagiamento Automático do Sono.....</i>	<i>97</i>
6.1	Introdução.....	97
6.2	Estagiadores do Sono.....	97
6.3	Sistema Proposto.....	99

6.3.1 Pré-processamento dos Dados.....	99
6.3.2 Pós-Processamento	102
6.4 Software Desenvolvido.....	102
6.4.1 Objetos do Sistema	102
6.4.2 Protótipo – Estagiador Automático Mapa FAN	104
6.5 Aplicação	108
6.5.1 Os dados.....	108
6.5.2 Os parâmetros do Sistema	109
6.5.3 Resultados	112
6.5.4 Análise dos Resultados	117
6.6 Conclusão	120
7 Conclusões e Recomendações.....	121
7.1 Conclusões.....	121
7.2 Recomendações	122
<i>Bibliografia</i>	<i>124</i>

LISTA DE FIGURAS

<i>Figura 1.1: Desenvolvimento da Pesquisa.....</i>	9
<i>Figura 2.1: Primeiro EEG registrado por Hans Berger, aproximadamente em 1928 (Fonte: Sabatinni, 1997).....</i>	11
<i>Figura 2.2: Registro polissonográfico obtido por um equipamento polissonográficos.....</i>	17
<i>Figura 2.3: Diagrama dos principais registros da polissonografia.....</i>	17
<i>Figura 2.4: Diagrama esquemático dos eletrodos para a tomada do EEG. Posição dos eletrodos: Frontal (F), Pólo Frontal (Fp), Central (C), Parietal (P), Occipital (O), Temporal (T).....</i>	20
<i>Figura 2.5: EEG da vigília.....</i>	23
<i>Figura 2.6: EEG em estágio 1.....</i>	24
<i>Figura 2.7: EEG em estágio 2.....</i>	24
<i>Figura 2.8: EEG em estágio 3.....</i>	24
<i>Figura 2.9: EEG em estágio 4.....</i>	25
<i>Figura 2.10: EEG em estado REM.....</i>	25
<i>Figura 2.11 - Exemplo de hipnograma.....</i>	29
<i>Figura 3.1: Os limites entre o DSP e outras áreas de ciências, engenharias e matemática é difusa e com sobreposição.....</i>	45
<i>Figura 3.2: Esboço de um sistema discreto.....</i>	47
<i>Figura 3.3: Um exemplo de convolução de duas seqüências. $y(n)$ é a convolução de $h(n)$ e $x(n)$.....</i>	50
<i>Figura 3.4 - Cross-Correlação do sinal s.....</i>	52
<i>Figura 4.1 Amostragem em função do tempo e seu espectro (DFT).....</i>	63
<i>Figura 4.2: Transformada wavelet de Haar da figura original a esquerda.....</i>	67
<i>Figura 4.3 Diagrama simplificado de um filtro digital.....</i>	69
<i>Figura 4.4 Uma representação conceitual de um filtro digital.....</i>	70
<i>Figura 4.5: Ilustração de sobreposição espectral entre o sinal e a interferência.....</i>	77
<i>Figura 4.6 Estrutura de um filtro FIR.....</i>	79
<i>Figura 5.1 Amostra (30 s) do sinal do EEG do canal C3.....</i>	83
<i>Figura 5.2: Trechos do sinal (amostras).....</i>	84
<i>Figura 5.3 Arquitetura da Sistema Mapa FAN.....</i>	85
<i>Figura 5.4 – Ordenação de uma amostra do sinal do canal C3 do EEG.....</i>	87
<i>Figura 5.5: Mostra o efeito da ordenação dos sinais para a fase acordado (vigília) e o estágio 4 do sono NREM (utilizando uma amostra de 3 segundos).....</i>	88
<i>Figura 5.6: Aprendizagem no Mapa_C indicada pela matriz do padrão de entrada.....</i>	92
<i>Figura 5.7: Intersecção entre um padrão de entrada (quadrados pequenos com bordas) e um mapa treinado (onde o nível de cinza caracteriza o grau de reforço de uma célula) ..</i>	94
<i>Figura 6.1 : Arquitetura do Sistema Mapa FAN para o Estagiamento Automático do Sono.....</i>	99
<i>Figura 6.2: Trecho do sinal biológico original com o limite superior e o limite inferior.....</i>	100
<i>Figura 6.3: Divisão da amostra em n segmentos.....</i>	101
<i>Figura 6.4: Estrutura Todo-Parte dos objetos do Protótipo Estagiador A. Mapa FAN.....</i>	103
<i>Figura 6.5: Troca de mensagens entre os objetos durante o treinamento.....</i>	103
<i>Figura 6.6: Troca de mensagens durante o reconhecimento.....</i>	104
<i>Figura 6.7: Painel de conversão de arquivos.....</i>	105
<i>Figura 6.8: Painel Estagiador Mapa FAN realizando o treinamento.....</i>	106

<i>Figura 6.9: Painel Estagiador Mapa FAN realizando o teste</i>	<i>107</i>
<i>Figura 6.10: Painel dos resultados gráficos.....</i>	<i>108</i>
<i>Figura 6.11: Visão tridimensional dos Mapas FAN treinados -Parte superior refere-se a classe REM/Estágio 1 e a parte inferior a classe Vigília</i>	<i>111</i>
<i>Figura 6.12: Parte superior apresenta o hipnograma do paciente P1 (paciente do treinamento) segundo o estagiamento do sistema e a parte inferior referente ao médico</i>	<i>113</i>
<i>Figura 6.13: Parte superior apresenta o hipnograma do paciente P2 segundo o estagiamento do sistema e a parte inferior referente ao médico.....</i>	<i>113</i>
<i>Figura 6.14: Parte superior apresenta o hipnograma do paciente P3 segundo o estagiamento do sistema e a parte inferior referente ao médico.....</i>	<i>114</i>
<i>Figura 6.15: Parte superior apresenta o hipnograma do paciente P4 segundo o estagiamento do sistema e a parte inferior referente ao médico.....</i>	<i>115</i>
<i>Figura 6.16: Apresenta a semelhança visual dos padrões do Est3/4 para os pacientes P1 (superior) e P2 (central) e a diferença entre os pacientes P1 e P7 (inferior)</i>	<i>119</i>
<i>Figura 6.17: Apresenta a variação de padrões da vigília</i>	<i>120</i>

LISTA DE TABELAS

<i>Tabela 4.1 Coeficientes dos filtros dados nos exemplos anteriores</i>	<i>72</i>
<i>Tabela 6.1 – Pacientes</i>	<i>109</i>
<i>Tabela 6.2 - Distribuição do Acerto para o Paciente de treinamento (P1).....</i>	<i>112</i>
<i>Tabela 6.3 - Distribuição do Acerto para o Paciente P2.....</i>	<i>112</i>
<i>Tabela 6.4 - Distribuição do Acerto para os Pacientes P3 e P4.....</i>	<i>114</i>
<i>Tabela 6.5 - Distribuição do Acerto para os Pacientes P5 e P6.....</i>	<i>117</i>
<i>Tabela 6.6 - Distribuição do Acerto para os Pacientes P7 e P8.....</i>	<i>117</i>
<i>Tabela 6.7 - Distribuição do Acerto usando o Paciente P2 para o treinamento</i>	<i>117</i>

LISTA DE QUADROS

<i>Quadro 2.1 - Breve histórico da Medicina do Sono</i>	<i>15</i>
<i>Quadro 2.2 – Classificação das frequências cerebrais</i>	<i>19</i>
<i>Quadro 2.3 - Polissonografia Computadorizada</i>	<i>21</i>
<i>Quadro 2.4 – Regras para o Estagiamento do Sono</i>	<i>26</i>
<i>Quadro 2.5 - Generalidades do sono normal de um jovem adulto.....</i>	<i>28</i>
<i>Quadro 2.6 – Classificação Internacional dos Distúrbios do Sono</i>	<i>30</i>
<i>Quadro 3.1 - Resumo das operações chaves em DSP e suas aplicações.....</i>	<i>49</i>
<i>Quadro 4.1 – Comparação entre a Transformada de Fourier e a de Wavelet.....</i>	<i>68</i>
<i>Quadro 4.2 – Comparação entre os Filtros IIR e os Filtros FIR.....</i>	<i>76</i>
<i>Quadro 4.3 – Aplicações dos Filtros Adaptativos.....</i>	<i>78</i>

LISTA DE GRÁFICOS

<i>Gráfico 6.1 -Histograma mostrando a distribuição por classe do paciente P1.....</i>	<i>115</i>
<i>Gráfico 6.2 - Histograma mostrando a distribuição por classe do paciente P2.....</i>	<i>116</i>
<i>Gráfico 6.3 - Histograma mostrando a distribuição por classe do paciente P3.....</i>	<i>116</i>
<i>Gráfico 6.4 - Histograma mostrando a distribuição por classe do paciente P4.....</i>	<i>116</i>

RESUMO

Este trabalho apresenta um novo método para a classificação automática dos estágios do sono utilizando um canal do eletroencefalograma (C_3). O sistema de classificação consiste de três módulos: o pré-processamento com extração de características, o classificador Mapa FAN, e um pós-processamento. A extração de característica consiste na ordenação e na redução de dimensão do sinal digital em cada época. O Mapa FAN é um sistema de classificação baseado na tecnologia de redes neurais artificiais, onde cada classe de padrões é representada por um mapa (matriz bidimensional). Para todo o padrão de entrada, cada mapa gera o grau de ativação daquele padrão em relação à classe que o mapa representa. Os Mapas foram treinados com os dados de um paciente e testados em outros sete pacientes, usando épocas de 30 segundos. Após a classificação feita pelo Mapa FAN, um sistema de regras de inferência, baseadas em estudos sobre a evolução do sono durante a noite, é aplicado para corrigir algumas falhas da classificação. Os resultados da classificação comparados com os de um especialista humano alcançaram uma concordância de 60 a 80%. Esses resultados estão dentro dos limites encontrados por outros pesquisadores, o que comprova a eficácia do modelo. Portanto, o sistema Mapa FAN pode ser utilizado neste e em outros problemas de reconhecimento de padrões que apresentam multidimensionalidade.

ABSTRACT

This work presents a novel method to perform automatic sleep stage classification using the central electroencephalogram electrode sign (C_3). The classification system consists of three modules: the pre-processing with features extraction, the FAN Map (Free Associative Neuron) classifier, and the post-processing. The features extraction module consists of the ordination and in the dimension reduction of the digital sign in each epoch. The FAN Map is a classification system based on the technology of neural networks. A map is generated to represent each class of pattern (a bi-dimensional matrix). For each input pattern, every map generates the degree of activation of that pattern in relation to the class the map represents. The Maps were trained using a specific patient's data and tested in other seven patients by 30 seconds epochs. After the FAN Map processes the classification, a system of inference rules is applied to correct some errors of the Maps. That system is based on studies about the evolution of the sleep during the night. The classification results compared to those of a human expert reached a 60% to 80% of agreement. Those results are within the limits found by other researchers, which proves the effectiveness of the model. Therefore, the FAN Map system can be used in this and in other problems of multidimensionality pattern recognition.

1

Introdução

1.1 Origem do trabalho

Este trabalho tem a sua origem em duas áreas distintas, mas que estão interligadas pelo objeto de estudo - os sinais digitais. Estas duas áreas são: o processamento de sinais digitais e a classificação dos estágios do sono através de sinais biológicos.

1.1.1 Processamento de Sinais

Toda a vida humana baseia-se em sinais, que são medidos, processados, analisados, e dão origem a decisões. O som, a temperatura e a luz são exemplos de sinais que são utilizados no dia a dia. Os ouvidos convertem o som em sinais elétricos, que chegam ao cérebro, e este é capaz de analisar algumas das suas propriedades, tais como amplitude, frequência e fase, determinar a direção em que se encontra a fonte de som, e reconhecê-lo, como a música, a fala, e o ruído de um automóvel. Os nervos colocados nas partes expostas da pele sentem a temperatura e enviam sinais elétricos para o cérebro, que podem originar decisões tais como ligar um aquecedor, e abrir uma janela. Os olhos focam as imagens na retina, que converte essas imagens em sinais elétricos e os envia para o cérebro, que, pela análise da cor, da forma, da intensidade, e da luz é capaz de reconhecer objetos, medir distâncias, e detectar o movimento.

Os desenvolvimentos que nos últimos anos se verificaram na microeletrônica, tornaram possível por em prática a idéia de uma forma efetiva de Processamento Digital de Sinal (DSP – *Digital Signal Processing*), disciplina que hoje ocupa um papel

preponderante nas telecomunicações, no controle, na instrumentação, na engenharia biomédica.

Diversos avanços importantes em DSP, nas últimas décadas, tal como modulação, compressão de sinal, correção de erro, ajudaram a tornar possível o mundo Web, o ensino a distância, o celular, e TV a cabo. Contudo, devido à maturidade de muitas idéias-chaves nessa área, as pesquisas no futuro provavelmente se bifurcarão em avanços comerciais práticos e a elaboração de projetos para mover a tecnologia de refinamento para desenvolvimento difundido, e a procura por abordagens fundamentalmente novas e diferentes para a resolução de problemas mais complexos (Madisetti, 2000).

Apesar do assunto ser DSP, não se pode esquecer que as informações são transformadas em sinais para serem distribuídas através das linhas telefônicas, antenas, satélites, fibras ópticas (internet) e, mais recentemente, por ondas (como o laser). Segundo Ackenhusen (1995), pode-se considerar o processamento de sinais como a conversão de grandes quantidades de dados em formas concentradas de informação. Já Enders Robinson (2000) diz que a história da idade da informação é a história do processamento de sinais. Muitas das coisas que a população desfruta hoje, desde a música que ouvem em um *CD-player* até os sistemas biomédicos que salvam vidas, dependem da tecnologia sobre processamento de sinais.

O vertiginoso desenvolvimento tecnológico da eletrônica e das técnicas de DSP, acoplado ao crescimento no conhecimento científico sobre as causas orgânicas das doenças humanas neste final de século, possibilitou um grande desenvolvimento de novos equipamentos e técnicas diagnósticas e terapêuticas na Medicina (Sabbatini, 1997). Tudo começou na década de 20, quando surgiu o primeiro eletrocardiógrafo, e em seguida, na década de 30, o eletroencefalógrafo. Ambos revolucionaram a cardiologia e a neurologia, respectivamente, e introduziram um novo conceito na esfera médica: o sinal biológico. Por exemplo, o ECG (eletrocardiograma) caracteriza a evolução temporal dos potenciais de ativação elétrica do tecido muscular cardíaco e o EEG (eletroencefalograma) caracteriza a evolução temporal da somatória dos potenciais de membrana dos neurônios encefálicos.

1.1.2 O sono e os sinais biológicos

Durante muito tempo a comunidade científica esteve, por ironia do destino, “adormecida” para a complexidade e a dinâmica que envolve o processo do sono. “Até o

século XVIII admitia-se que o corpo material experimentava a morte periódica no sono" (Jouvet, 1977), que até então era tido apenas como algo decorrente da ausência passiva do estado de vigília. No entanto, com os registros dos sinais elétricos do cérebro, "encontraram-se provas que confirmam a existência de estruturas cerebrais localizadas que induzem ativamente o sono" (Teitenbaum, 1969).

A ciência tem desvendado nobres funções do sono como as psicológicas, as intelectuais, as da memória, as do humor e as da aprendizagem. O sono parece ser o período mais fecundo para consolidar os traços mnemônicos e geradores de criatividade. Os prejuízos causados a ele diminuem a capacidade das funções superiores do cérebro, condenando suas vítimas a "cidadãos de segunda classe" (Jouvet, 1977; De Koninck et al., 1989; Pimentel-Souza, 1990).

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, tinha-se a idéia de que o sono representava 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.

A maioria dos conhecimentos sobre o sono veio através da polissonografia que é uma espécie de "radiografia" do sono. A polissonografia mostra uma sucessão de ondas cerebrais ordenadas e cíclicas de diferentes amplitudes e frequências, de movimentos oculares e de mudanças de tono muscular que são utilizados para o estagiamento do sono. A palavra quer dizer "múltiplos registros durante o sono". Registra-se: o EEG (ondas elétricas do cérebro), o eletrooculograma – EOG (movimentos dos olhos), o eletromiograma – EMG (tensão muscular), o ECG (ondas elétricas do coração), os movimentos respiratórios e a oxigenação do sangue (Carshadon e Rechtschaffen, 1994). Assim, controla-se o funcionamento do organismo durante o sono.

Graças a polissonografia, reconhece-se hoje que o sono não é um estado homogêneo, e que há dois estados distintos de sono¹: o sono REM (*Rapid Eye Movements*) e o sono NREM (Não REM). O sono mais surpreendente, o último a ser descoberto, é o sono REM onde ocorrem os movimentos rápidos dos olhos. O sono NREM foi dividido em outras quatro fases, chamadas de estágios de um a quatro.

¹ Maiores detalhes são encontrados no capítulo 2, na seção 2.4.

As regras para o estagiamento (classificação dos estágios do sono) do sono foram definidas por Rechtschaffen e Kales, em 1968, em um manual para padronização publicado pela *National Institute of Health* dos EUA. Estas regras ainda são utilizadas internacionalmente, pois, apesar das novas descobertas, ainda não foi criado um novo manual internacional. Porém, muitos pesquisadores já utilizam outros paradigmas, como Rosa et al. (1999).

A polissonografia é realizada em laboratórios do sono por meio de um equipamento especial usado por técnicos treinados. O exame tem uma duração aproximada de oito horas. A análise do traçado é feita com auxílio de um computador, o que economiza tempo. Mesmo assim, o estagiamento do sono requer muito tempo de um técnico com “olho treinado” e muita paciência. Nem todos os equipamentos de polissonografia são automatizados, e poucos possuem estagiamento automático. E os que possuem não inspiram total confiança aos técnicos da área (Martinez, 1999). O exame polissonográfico serve principalmente para diagnosticar os distúrbios do sono, como as insônias e as apnéias. Ele permite definir com maior precisão a causa e o tratamento correto destes distúrbios.

Segundo Carskadon e Dement (1994), o caso ideal de 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 toda noite em períodos de, aproximadamente, 90 minutos.

Os distúrbios do sono, bem como os 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 são a insônia e a sonolência excessiva.

A medicina do sono como especialidade clínica tem história recente. O primeiro centro de sono foi criado em Stanford, em 1970, para atender pacientes narcolépticos. Nas últimas décadas, a medicina do sono materializou-se. Surgiram sociedades do sono em todo o mundo e apareceram periódicos dedicados ao sono. No Brasil, existem 15 linhas de pesquisa sobre o sono cadastradas no Conselho Nacional de Desenvolvimento Científico e Tecnológico (Martinez, 1999). A sociedade brasileira de Sono existe desde 1985 e promove eventos a cada dois anos que reúnem em torno de 200 interessados.

1.2 Justificativas

Desde o momento em que a comunidade científica despertou para as questões pertinentes ao sono, várias pesquisas têm sido desenvolvidas. No entanto, essas pesquisas ainda são de cunho estruturalista, localizacionista (Martinez, 1999).

A análise dos registros polissonográficos durante o sono é uma técnica muito útil para a investigação do sistema nervoso central. Ele fornece informação sobre a atividade elétrica baseada nas medidas de registros elétricos tomadas sobre o couro cabeludo do paciente. As inferências e os estudos sobre a saúde dos pacientes e o efetivo tratamento de algumas doenças podem ser feitos e analisados a partir das informações obtidas desses registros. A polissonografia do sono é um ramo de pesquisa da medicina muito importante devido às aplicações clínicas (Martinez, 1999).

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 (ver item 2.4.1).

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 deste contexto, as regras de Rechtschaffen e Kales têm funcionado mais como um guia do que propriamente como definições exatas.

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 a fase REM e a fase Vigília. Os especialistas têm realizado o estagiamento do sono visualmente desde 1970. O especialista classifica cada amostra do registro (geralmente, de 30 s) em um dos seis estágios.

Porém, esta é uma tarefa tediosa que consome de 3 a 6 horas de anotações e cuidadosa observação de um técnico (para classificar os registros de uma noite de um paciente) e ainda está sujeita a enganos devido à complexidade dos sinais e da própria

classificação. Por esse motivo, muito esforço tem sido gasto em projetar estagiadores automáticos de sono.

Nos últimos trinta anos diferentes métodos automáticos têm sido desenvolvidos com o objetivo de suprir a classificação visual, como: métodos estatísticos e sistemas especialistas (Burger, Cantani e West, 1977; Ray, Lee e Morgan, 1986; Kufrin, 1997). Nas duas últimas décadas diversos trabalhos introduziram o uso de técnicas de inteligência artificial, principalmente de redes neurais (RN), como uma ferramenta para a classificação automática do sono (Principee Tome, 1989; Nielsen et al., 1997; Mota et al, 1999; Oropesa et al., 1999, Tafner, 1999, Souza, 1999).

Os resultados são diferentes de um sistema para outro. O desempenho varia num intervalo de 60 a 90 % de reconhecimento. Uma comparação rigorosa entre os sistemas é muito difícil, pois eles diferem nas condições dos registros, na forma de estagiamento do especialista e nos processos de validação. Porém, os sistemas desenvolvidos ainda não generalizam o suficiente para ser aceito comercialmente por médicos e especialistas em sono (Martinez, 1999).

Uma observação importante a fazer é que a captura dos dados (pelos aparelhos de polissonografia) é realizada, geralmente, a uma taxa de 50Hz, 100Hz ou 200 Hz. Dessa forma, numa amostra de 30 segundos a 200Hz tem-se 6000 pontos. Nesse caso, tem-se aqui um padrão (amostra) com dimensão de 6000, ou 6000 características, o que identifica um problema de alta dimensão.

O tratamento com padrões que possuem uma quantidade muito grande de características é objeto de estudo e preocupação para muitos pesquisadores há várias décadas (Bellman, 1961, Duda e Hart, 1973). Porém, nas duas últimas décadas a busca, por métodos mais sofisticados e eficientes, tornou-se mais intensa, pois se começou a explorar as informações contidas em dados de alta dimensão, como as imagens e os sinais (Schowengerdt, 1997, Souza, 1999).

De um modo geral, os métodos apresentam duas etapas. A primeira etapa consiste no pré-processamento de sinal biológico, onde o sinal é filtrado e a extração de características é realizada. Essa etapa utiliza técnicas de DSP. A segunda etapa é o estagiamento propriamente dito através de um método automático de classificação. Porém, esses métodos sempre procuram reduzir a dimensão do problema através da extração de características.

Devido ao problema da multidimensionalidade dos padrões (Carreira-Perpiñán, 1997), muitos pesquisadores, buscam métodos para extrair as características relevantes antes de verificar a possibilidade de desenvolver métodos de classificação que trabalhem com os padrões em seu espaço original. Neste trabalho, o método proposto utiliza os dados no espaço de alta dimensão. Preocupando-se também com a forma de representar os dados tendo em vista o problema e o novo método utilizado para a classificação.

1.3 Objetivos do Trabalho

1.3.1 Objetivo Geral

Desenvolver um modelo para classificação de sinais digitais multidimensionais (sinais dispostos no tempo com uma determinada frequência de captura), onde a classificação é realizada por trechos. Particularmente, o foco do modelo será o estagiamento automático das fases do sono utilizando um canal do Eletroencefalograma.

1.3.2 Objetivos Específicos

Como objetivos específicos este trabalho apresenta:

- a) Desenvolvimento de um método de pré-processamento (ordenação) e um método de classificação (Mapa FAN²) para trabalhar com padrões em alta dimensão, especificamente sinais digitais;
- b) Desenvolvimento de um sistema para a realização do estagiamento automático (classificação dos estágios) do sono através de um canal de EEG coletados por um equipamento de polissonografia digital, com o objetivo de auxiliar os especialistas do sono e/ou os neurofisiologistas no processamento de longos registros de sinais de EEG.
- c) Realizar pré-processamentos nos sinais digitais adquiridos pelo sistema de polissonografia para melhorar a representatividade destes sinais. Em relação a este pré-processamento tem-se como metas:
 - escolher o canal do EEG que será utilizado;
 - extrair ruídos dos sinais;
 - padronizar os sinais (ordenação);

² FAN – *Free Associative Neuron*

- extrair as características que serão usadas para a realização da classificação dos estágios do sono.
- d) Efetuar a classificação dos estágios do sono usando o novo método de classificação.
- e) Realizar um pós-processamento através de regras para corrigir algumas falhas do método de classificação.
- f) Implementar o protótipo para o estagiamento automático do sono.

1.4 Metodologia de desenvolvimento da Pesquisa

Para alcançar os objetivos propostos o trabalho foi dividido em diversas etapas, que juntas, integram o trabalho desenvolvido.

A primeira etapa consiste do levantamento bibliográfico (através de livros, revistas, internet, entrevistas com especialistas, empresa EMSA³, entre outros.) acerca do problema do estagiamento do sono manual e automático, sobre as técnicas de processamento de sinais (filtros) e de reconhecimento de padrões (extração de características, classificação), e inteligência artificial.

Uma vez conhecidos os problemas do processamento de sinal, das técnicas de classificação e do estagiamento automático do sono, buscam-se formas alternativas de trabalhar com os dados de eletroencefalograma. Desenvolve-se dois novos métodos: a ordenação dos sinais, uma forma alternativa de pré-processar os dados (baseado na teoria da informação); e o Mapa FAN, um classificador de padrões para problemas de alta dimensão, baseado nas técnicas de inteligência artificial (redes neurais e sistemas difusos).

Tendo desenvolvido os modelos, o próximo passo é a sua validação. Nesta etapa implementa-se o sistema, chamado Mapa FAN, o qual se compõe de três etapas: o pré-processamento, a classificação e o pós-processamento baseado em regras. O sistema é utilizado para realizar estagiamento do sono de quatro pacientes, onde um deles é usado para o treinamento e os outros para os testes. Nesta fase são feitos os ajustes dos parâmetros do sistema e das regras do pós-processamento e é escolhido o canal de EEG a ser utilizado

A última etapa consiste das considerações finais sobre a pesquisa.

³ EMSA – Equipamentos Médicos S/A.

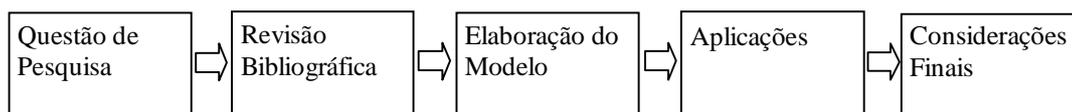


Figura 1.1: Desenvolvimento da Pesquisa

1.5 Estrutura do Trabalho

Este trabalho está estruturado em 8 capítulos, seguidos da referência bibliográfica.

O capítulo 1 - **Introdução** - apresenta aspectos preliminares do trabalho, bem como a apresentação do tema, sua importância, os objetivos do trabalho e sua respectiva estruturação.

No capítulo 2 – **O sono** - tem-se uma revisão teórica sobre o sono e sua estrutura. Os registros polissonográficos, o estagiamento dos estágios do sono e as suas dificuldades, e os estagiadores automáticos existentes, também são focos desse capítulo.

O capítulo 3 – **Processamento de Sinal Digital** - apresenta uma breve revisão teórica sobre o processamento de sinal digital (DSP): a sua história, as principais operações, as vantagens em relação ao processamento analogia, e as tendências futuras.

No capítulo 4 – **Transformadas e Filtros Digitais** - tem-se uma descrição mais detalhada sobre duas operações importantes em DSP: as transformadas e os filtros.

O capítulo 5 - **Método Proposto: O Sistema Mapa FAN** - apresenta a arquitetura do sistema de classificação Mapa FAN, uma forma alternativa de pré-processamento de sinais (ordenação) e define o classificador Mapa FAN (treinamento e teste).

O capítulo 6 – **Aplicação: Estagiamento Automático do Sono** – traz a arquitetura do sistema Mapa FAN, com o pré-processamento, o classificador desenvolvido, e as regras do pós-processamento, juntamente com os resultados obtidos no estagiamento automático do sono.

Finalmente o capítulo 7 traz as conclusões e as considerações finais sobre a pesquisa desenvolvida.

2

O Sono

“Os homens compartilham um único mundo, a não ser durante o sono, onde cada um habita o seu próprio” (Heráclito)

2.1 Introdução

Segundo Martinez (1999), o sono não é uma função do organismo, como é o caso da digestão, mas um estado alterado da consciência com inúmeras funções, muitas das quais relacionadas à conservação de energia. O sono tem várias definições (Martinez, 1999) - meramente descritivas ou tautológicas – que pouco contribuem para avançar no conhecimento do fenômeno. Uma delas: “O sono é um estado fisiológico caracterizado por abolição prontamente reversível da consciência, por quiescência motora relativa e por elevação do limiar de respostas ao meio ambiente, que ocorre em episódios periódicos”. Outra: “O sono é o estado fisiológico que interrompe a vigília e permite restaurar as condições do início da vigília precedente”.

Durante muito tempo a comunidade científica esteve, por ironia do destino, “adormecida” para a complexidade e a dinâmica que envolve o processo do sono. “Até o século XVIII admitia-se que o corpo material experimentava a morte periódica no sono” (Jouvet, 1977), que até então era tido apenas como algo decorrente da ausência passiva do estado de vigília. No entanto, “encontraram-se provas que confirmam a existência de estruturas cerebrais localizadas que induzem ativamente o sono” (Teitenbaum, 1969).

Desde o momento em que a comunidade científica despertou para as questões pertinentes ao sono, várias pesquisas têm sido desenvolvidas. No entanto, essas pesquisas ainda são de cunho estruturalista e localizacionista (Martinez, 1999).

A ciência tem desvendado nobres funções do sono como as psicológicas, as intelectuais, as da memória, as do humor e as da aprendizagem (Pimentel-Souza, 1990). O

sono parece ser o período mais fecundo para consolidar os traços mnemônicos e geradores de criatividade. Os prejuízos causados a ele diminuem a capacidade das funções superiores do cérebro, condenando suas vítimas a “cidadãos de segunda classe” (Jouvet, 1977; De Koninck et al., 1989; Pimentel-Souza, 1990).

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 a polissonografia, reconhece-se hoje que o sono não é um estado homogêneo, e que há dois estados distintos de sono: o sono REM (*Rapid Eye Movements*) e o sono NREM (Não REM). O sono mais surpreendente, o último a ser descoberto, é o sono REM onde ocorrem os movimentos rápidos dos olhos. O sono NREM foi dividido em outras quatro fases, chamadas de estágios de um a quatro (que serão devidamente explicados na seção 2.4).

2.2 Evolução

Considerou-se o sono sempre um estado homogêneo, de repouso, um período passivo, de desligamento. Esse conceito mudou quando se passou a registrar a atividade cortical por meio do eletroencefalograma. Desde o século XIX, conhecia-se a atividade elétrica cerebral em animais, obtida durante vivissecção. Berger, um neuropsiquiatra clínico alemão, da Universidade de Jena, foi o primeiro a registrar a atividade elétrica do cérebro humano (Sabatinni, 1997) (Figura 2.1). Para tal, pesquisou anos até desenvolver amplificadores extremamente sensíveis.



Figura 2.1: Primeiro EEG registrado por Hans Berger, aproximadamente em 1928 (Fonte: Sabatinni, 1997)

Berger iniciou seus experimentos de forma secreta, na tentativa de desenvolver a telepatia. Nessa época, a crença na possibilidade de telepatia era forte, uma vez que anos antes a transmissão de ondas de rádio mostrara-se possível (Duffy et al., -). Grande parte do folclore existente ainda hoje em relação às ondas cerebrais provém dessa época.

A publicação de seus achados, em 1929, veio após anos de pesquisa cuidadosa e esmerada, na qual ele tentou provar a origem cerebral do fenômeno. Ele anunciou ao mundo científico e médico que (Sabattini, 1997):

- era possível registrar as fracas correntes elétricas geradas no cérebro humano, sem a necessidade de abrir o crânio, e mostrá-las na forma de um registro em papel. Berger denominou a esta nova forma de registro fisiológico de eletroencefalograma (ou EEG); e
- essa atividade mudava de características de acordo com o estado funcional do cérebro, tais como no sono, na anestesia, na hipóxia (falta de oxigênio) e em certas doenças nervosas, como a na epilepsia.

No entanto, sua conclusão modesta, “acredito, portanto, na verdade, que descobri o eletroencefalograma do homem e que publiquei aqui pela primeira vez”, foi recebida com descrença e falta de confiança (Duffy et al., -)⁴.

Foi somente em 1934, quando Adrian e Matthews, na Inglaterra, repetiram os experimentos de Berger e confirmaram suas observações, que sua obra tornou-se aceita pela comunidade científica (Duffy et al., -).

Os 14 artigos de Berger (publicados) sobre a atividade elétrica do cérebro humano contêm um grande número de observações originais sobre o EEG. Berger foi o primeiro a observar e descrever precisamente muitas das características do EEG que se conhece hoje. Ele demonstrou que: a) a atividade elétrica cerebral consiste mais ou menos de uma mistura de flutuações de voltagem rítmicas sinusoidais, tendo uma frequência de aproximadamente 1 a 60 oscilações por segundo; e b) as ondas mais facilmente reconhecidas tinham uma frequência de aproximadamente 10 oscilações por segundo, e ele as chamou *alfa*. As ondas *alfa*, relata ele, tendiam a desaparecer com a atenção. Berger também observou que o EEG tinha diferentes aspectos nos distúrbios neurológicos, como a epilepsia, os traumas e os tumores. Ele foi o primeiro a registrar uma crise epilética.

⁴ Berger foi afastado da direção do hospital de Jena pelos nazistas em 1934 e suicidou-se em 1941.

Seguindo o trabalho pioneiro de Berger, o interesse em eletroencefalografia e em atividade elétrica cerebral - “ondas cerebrais” – tornou-se generalizado nas décadas de 30 e 40. Frederick e Erna Gibbs, Hallowell e Pauline Davis, Donald Lindsley, nos Estados Unidos, Herbert Jasper, no Canadá, e W. Grey Walter, na Inglaterra, apenas para citar alguns dos pesquisadores, mostraram a importância do EEG e de suas aplicações em neurologia e neurocirurgia (Duffy et al., -). Desde então, o EEG tornou-se um procedimento clínico de rotina de considerável valor diagnóstico, bem como um poderoso instrumento de pesquisa na neurociência.

A primeira tentativa de classificar o sono em fases surgiu em 1935 com a descrição, realizada por Loomis, dos diferentes padrões do EEG durante o sono (Loomis et al., 1935). Nessa época, porém, o interesse em registrar o sono era limitadíssimo; nos raros centros de pesquisa do sono o EEG era registrado por apenas alguns segundos, para economizar papel. Somente após a Segunda Guerra Mundial, nos EUA, a pesquisa passou a obter verbas fabulosas. Isso teve reflexo importante no estudo do sono, pois permitiu que se usassem os quilômetros de papel necessários para registrar o sono por noites inteiras.

Segundo Martinez (1999), Nathaniel Kleitman publicou um dos primeiros e mais completos livros sobre sono em 1939. Na segunda edição, em 1963, ele cita 4337 referências bibliográficas, datando, muitas delas, do século passado. Kleitman foi homenageado com grandes circunstâncias na reunião anual da ASDA (*American Sleep Disorders Association*) em 1995, ao completar 100 anos de vida. Seu livro demonstra que a pesquisa já foi mais criativa e também mais cruel que hoje. O texto ostenta experiências de vivisseção de animais, choques elétricos e irradiação. Cita também tentativas de imitar a hibernação dos animais. Uma senhora com câncer, na tentativa de curar a doença, consentiu o seu resfriamento até 9°C e foi completamente reanimada após uma hora. Foram experiências quiméricas, com a marca do despertar científico – tecnológico da humanidade. Poucas das novas especialidades médicas têm um passado de criatividade comparável ao da pesquisa em sono.

As regras para o estagiamento do sono foram definidas por Rechtschaffen e Kales, em 1968, em um manual para padronização pública pelo *National Institute of Health* dos EUA. Estas regras ainda são utilizadas internacionalmente, pois, apesar das novas descobertas, ainda não foi criado um novo manual internacional. Porém, muitos pesquisadores já utilizam outros paradigmas, como Rosa et al. (1999).

A medicina do sono como especialidade clínica tem história recente. O primeiro centro de sono foi criado em Stanford, em 1970, para atender pacientes narcolépticos. Nas últimas décadas, a medicina do sono materializou-se. Surgiram sociedades do sono em todo o mundo e apareceram periódicos dedicados ao sono. No Brasil, existem 15 linhas de pesquisa sobre o sono cadastradas no Conselho Nacional de Desenvolvimento Científico e Tecnológico (Martinez, 1999). A sociedade brasileira de Sono existe desde 1985 e promove eventos a cada dois anos que reúnem em torno de 200 interessados.

A especialidade organizou-se de forma moderna desde seu nascimento. Uma prova de excelência no estabelecimento das fundações da medicina do sono é a existência de um volume que baliza sua área do conhecimento, a Classificação Internacional dos Distúrbios do Sono. Uma faceta importante da Classificação dos Distúrbios do Sono é seu caráter internacional e globalizado.

As sociedades - americana, européia, australiana, japonesa e latina-americana - consultadas opinaram e compuseram esse marco da especialidade, publicado em 1990. A Classificação Internacional dos Distúrbios do Sono permite usar códigos unificados para classificação das doenças do sono. A partir da décima edição da Classificação Internacional das Doenças, CDI - 10, uma parte dos 84 distúrbios do repertório da medicina do sono já pode ser codificada (Martinez, 1999).

A pesquisa sobre o sono tem história longa, mais longa que a dos transplantes. Ainda não granjeou, porém, respeitabilidade e publicidade como as cirurgias de troca de órgãos. As especialidades que se dedicam a um estado de vida, e não a um órgão ou sistema específico, são relativamente novas. Algumas das “especialidades de estado” adquiriram legitimidade, como a medicina do esporte, do trabalho e do tráfego. O sono é um estado da vida, assim como o trabalho ou o esporte. A medicina do sono, apesar de sua maior relevância – todos dormem, mas nem todos fazem esporte, por exemplo – e do vulto dos conhecimentos acumulados, é reconhecida de fato, mas não de direito (Martinez, 1999). A *American Medical Association* aceita a medicina do sono como especialidade ad hoc, ou seja, o médico pode intitular-se especialista se comprovar que atende pacientes com distúrbios do sono.

Quadro 2.1 - Breve histórico da Medicina do Sono

Até o século XVIII	O sono era considerado um estado passivo.
1924	Berger registrou pela primeira vez a atividade elétrica do cérebro humano. O sono é considerado um estado ativo.
1929	Berger publicou os resultados de sua pesquisa sobre o sono. Os resultados não foram aceitos.
1934	Adria e Matthews refizeram os experimentos de Berger. Com isto as pesquisas de Berger foram aceitas e pesquisadores continuaram as pesquisas.
1935	Primeira tentativa de classificar o sono (Loomis et al., 1935).
Após a Segunda Guerra Mundial	A pesquisa sobre o sono começou a receber apoio financeiro nos EUA.
1939	Kleitman publicou um dos primeiros e mais completo livro sobre o sono.
1968	Definição internacional das regras de estagiamento do sono por Rechtschaffen e Kales.
1970	Criado o primeiro laboratório do sono em Stanford.
1985	Criada a Sociedade Brasileira do Sono.
1990	Foi realizada a classificação internacional dos distúrbios do sono (Martinez, 1999).
2000	A medicina do sono ainda não é considerada uma especialidade médica. O sono ainda é um mistério a ser desvendado.

2.3 A polissonografia

A maioria dos conhecimentos sobre o sono veio através da polissonografia (Figura 2.2) que é uma espécie de "radiografia" do sono. O nome quer dizer "múltiplos registros durante o sono". Registra-se: o eletroencefalograma – EEG (ondas elétricas do cérebro), o eletrooculograma – EOG (movimentos dos olhos), o eletromiograma – EMG (tensão muscular), eletrocardiograma - ECG (ondas elétricas do coração), movimentos respiratórios e a oxigenação do sangue (Carshadon e Rechtschaffen, 1994). Assim, controla-se o funcionamento do organismo 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 (Figura 2.3). Usa-se a derivação bipolar de um par, mantendo-se o terceiro eletrodo como reserva para ocorrência de falha de um deles.

Segundo Guiot (1996), a polissonografia abrange 3 etapas distintas, as duas primeiras correspondendo a 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 se referem aos distúrbios específicos do sono. As medidas mais utilizadas são:

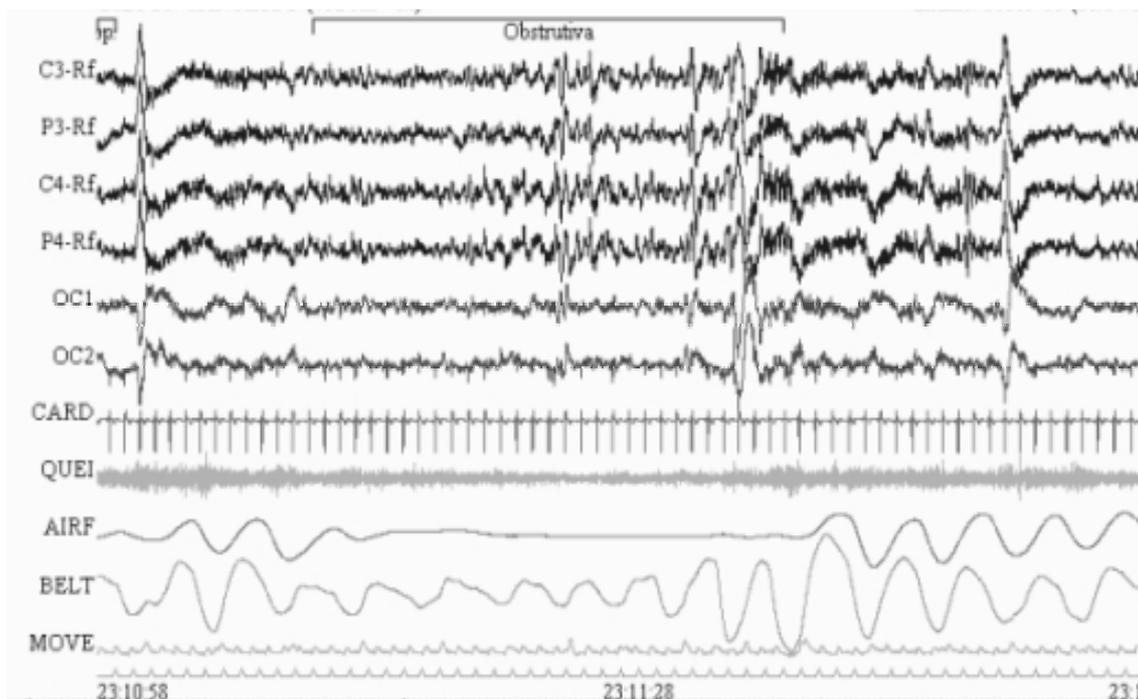
Tempo Total de Registro (TTR): considerado a partir do momento em que as luzes são apagadas e o final da noite;

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

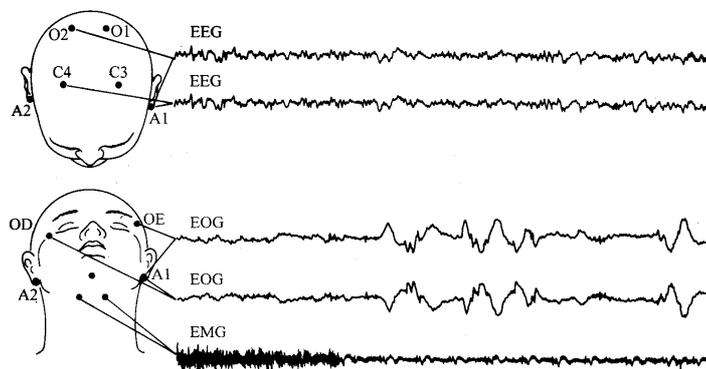
Tempo Total de Sono (TTS): considerado a partir do início do sono até o término, excluindo possíveis despertares depois do início;

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

A polissonografia é realizada em laboratórios do sono por meio de equipamento especial usado por técnicos treinados. O exame tem uma duração aproximada de oito horas, em geral, entre 23:00 e 07:00 horas. A análise do traçado é feita com auxílio do computador, o que economiza tempo. Mesmo assim, 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. E os que possuem não inspiram total confiança aos técnicos da área.



*Figura 2.2: Registro polissonográfico obtido por um equipamento polissonográficos
Fonte: Empresa EMSA*



*Figura 2.3: Diagrama dos principais registros da
polissonografia
Fonte: Guiot, 1996*

O exame polissonográfico serve principalmente para diagnosticar os distúrbios do sono. Ele permite definir com maior precisão a causa e o tratamento correto destes distúrbios.

2.3.1 Registros

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

Eletroencefalograma (EEG): O EEG é o registro elétrico contínuo da superfície do cérebro, onde a intensidade e os padrões dessa atividade contínua são determinados, em grande parte, pelo nível global de excitação resultante do sono, da vigília e sintomas como epilepsia (Schauff et al., 1993). A intensidade elétrica da onda pode variar de 0 a 200 μV , e sua frequência pode variar de 1 a 50 Hz⁵. As ondas cerebrais, normalmente, são classificadas segundo a sua frequência, sendo nomeadas como: alfa, beta, teta e delta. Segundo Schauff et al. (1993), a classificação das ondas cerebrais segue a distribuição mostrada no Quadro 2.2.

O registro do EEG deve ser tomado diretamente do crânio, segundo o sistema 10-20, cuja posição dos eletrodos obedece às normas internacionais recomendadas por Jasper em 1958 (Apud Carshadon e Rechtschaffen, 1994). As posições dos eletrodos estão demonstradas na Figura 2.4. O nome desse sistema, 10-20, vem da medida feita de intervalos de 10 ou 20 % da distância total entre as quatro marcas do sistema, são elas: nasion, inion (protuberância occipital externa) e os pontos pré-auriculares direito e esquerdo.

Segundo Carshadon e Rechtschaffen (1994), todas as ondas usadas do EEG para distinguir as fases 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 também têm utilizado o registro dos canais O1 e O2 como canais auxiliares. Os autores manifestam, ainda, que o EEG é o núcleo da polissonografia, e é através dele que, principalmente, as fases do sono são distinguidas.

Eletrooculograma (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*⁶), 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.

⁵ Unidade de medida de frequência definida como a frequência de um fenômeno cujo período tem a duração de um segundo; um ciclo por segundo.

⁶ Movimento Lento dos Olhos.

Quadro 2.2 – Classificação das freqüências cerebrais

Tipo	Características
Delta (δ)	<ul style="list-style-type: none"> - Freqüência: menor que 3,5 Hz - Presente, principalmente, em crianças com menos de 1 ano; durante o sono profundo; ou em doenças orgânicas graves do cérebro.
Teta (θ)	<ul style="list-style-type: none"> - Freqüência: 4 a 8 Hz - A atividade é acompanhada de sonolência - Predominante em crianças dos 2 aos 5 anos e em adultos com stress emocional - Mais evidente nas derivações parietais e temporais
Alfa (α)	<ul style="list-style-type: none"> - Freqüência: 8 a 13 Hz - Amplitude: 5 e 100 μV - Ocorre em indivíduos em vigília, principalmente com os olhos fechados sob condições de relaxamento físico e atividade mental relativa. - São encontrados na região occipital
Beta (β)	<ul style="list-style-type: none"> - Freqüência: 13 a 50 Hz - Amplitude: 20 μV ou menos - Mais evidente nas derivações frontais e parietais - São divididas em β_1 e β_2 que aparecem com o sujeito estressado ou sob pressão

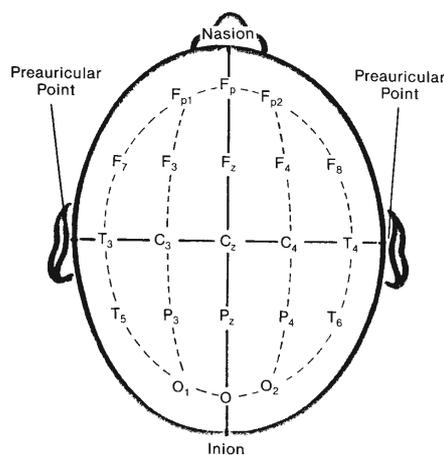


Figura 2.4: Diagrama esquemático dos eletrodos para a tomada do EEG. Posição dos eletrodos: Frontal (F), Pólo Frontal (Fp), Central (C), Parietal (P), Occipital (O), Temporal (T)
 Fonte: Carshadon e Rechtschaffen, 1994

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 (Figura 2.3). As posições desses eletrodos são conhecidas como ROC e LOC, *Right Outer Canthus*⁷ e *Left Outer Canthus*⁸ respectivamente.

Eletromiograma (EMG): Em um registro padrão de polissonografia, o registro da parte inferior do queixo é usado como um critério para a identificação da fase 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 tíbia⁹ é utilizado para verificar se o paciente possui movimentos periódicos durante o sono.

2.3.2 As perspectivas futuras

No futuro, talvez, o emprego de tecidos condutores de eletricidade eliminará o uso de eletrodos colocados no couro cabeludo, aumentando o conforto do paciente. Lençóis

⁷ Canto Externo Direito.

⁸ Canto Externo Esquerdo.

⁹ O mais grosso e mais interno dos dois ossos da perna.

feitos com esses materiais já permitem o registro de ECG e movimentos do corpo, da respiração e das pernas por contato com a pele (Martinez, 1999).

O emprego do computador no registro, na monitoração e na análise do sono torna-se, de forma gradativa, padrão. Alguns serviços ainda mantêm o registro em papel. As vantagens do computador, entretanto, são eloqüentes (Quadro 2.3)

Tornar a polissonografia mais tolerável e passível de ser feita na residência do paciente possibilitará estudos por várias noites consecutivas, e acarretará avanços no conhecimento do sono fora do laboratório.

Quadro 2.3 - Polissonografia Computadorizada

Modo de uso	Opções	Vantagens sobre o registro em papel
Registro	- Disposição dos canais na tela - Armazenamento em CD-ROM	- Flexibilidade Economia de papel, tinta e de espaço de armazenagem
Monitorização	- Base de tempo variável - Assistida Desassistida	- Visualização rápida de longos períodos - Mais amigável para o técnico - Computador detecta problemas e sinaliza
Estagiamento	- Humano - Auxiliado pelo computador - Automático	- Laudo automático, sem necessidade de cálculos - Acelera a análise humana Em desenvolvimento. Dispensará revisão humana.

Fonte: Martinez, 1999

2.4 As Fases e a Estrutura do Sono

Para falar sobre as fases do sono é coerente começar pelo adormecer. Esse se caracteriza por ser o momento de transição entre o estado de vigília e a primeira fase do sono, que seria uma vigília descontraída. Tanto essa fase de transição como as seguintes só puderam ser distinguidas e analisadas através de um critério padronizado, incluindo registros de ondas cerebrais pelo eletroencefalograma (EEG). O EEG durante a vigília mostra "atividades cerebrais não sincronizadas, inconstantes e rápidas, de baixa voltagem, flutuando rapidamente entre 20 e 25 ciclos por segundo" (Kleitman, 1973; Reimão, 1996). Essa fase vai ser sucedida pela vigília descontraída, que é caracterizada pelo ritmo alfa, ondas cerebrais com uma amplitude relativamente grande e uma frequência que variam

entre 8 e 13 ciclos por segundo. Quando se adormece, a amplitude das ondas vai aumentando e o ritmo vai caindo para 4 a 6 ciclos por segundo. Nesse momento, pode-se passar, então, para o adormecimento propriamente dito, onde se tem uma diminuição progressiva do ritmo alfa e o aparecimento gradual de ondas "teta" (de frequência mais baixa). Num segundo estágio superficial do sono, ocorre a diminuição progressiva dos ritmos intercalados com "fusos" ("rajadas de ondas de maior amplitude, indicando que grupos de células corticais dispararam em uníssono") (Reimão, 1996) e seguidas de ondas "alfa".

Para que o indivíduo chegue a esse estágio é necessário que o ambiente esteja propício para ocorrer o sono (com um mínimo de ruído possível, temperatura e iluminação adequada), pois até este momento o limiar de despertar conserva-se baixo. Durante até essa fase de sono lento, o tônus muscular é mantido e o indivíduo ainda se encontra receptivo às informações do meio exterior.

Essas duas fases são como uma preparação para que o indivíduo possa, então, passar para os terceiro e quarto estágios, conceituados como sonos profundos, onde se têm registros majoritários de grandes amplitudes e ondas lentas delta (ondas de 3 a 4 Hz). Do ponto de vista físico, esses são os estágios mais reparadores.

Aqui se encontra a fronteira que "separa" o sono REM dos outros estágios. Dois fenômenos, neste momento, vão ocorrer, os tônicos e os fásicos. Cabe aos fenômenos tônicos a responsabilidade sobre as ondas cerebrais que vão representar uma atividade cortical e subcortical rápida, contínua e de baixa voltagem. Essa atividade se assemelha às encontradas no estado de vigília, o que significa, também, intensa atividade cerebral não reiterativa. Nesse momento de EEG ativado, o limiar de despertar do indivíduo é muito elevado e, por isto é também denominado sono paradoxal. Aqui há também um desaparecimento total do tônus muscular. Estas ocorrências caracterizam uma grande isolação do ser humano do ponto de vista motor e sensorial, à exceção da audição, nossa última guardiã de nossa segurança (Teitenbaum, 1969). Os fenômenos fásicos são representados por espículas de alta voltagem que começam na altura da ponte encefálica, nas proximidades dos núcleos oculomotores, passam pelo corpo geniculado lateral e atinge o córtex occipital. Estes fenômenos fásicos centrais são responsáveis pelos fenômenos fásicos/periféricos, tais como os movimentos oculares (Jouvet, 1977; Kleitman, 1973; Reimão, 1996).

2.4.1 As fases do Sono

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 Carshadon e Rechtschaffen (1994), para recém-nascidos e bebês utiliza-se um conjunto de critérios diferentes.

Vigília (*wakeful*): A maioria das pessoas exibe um EEG com ritmo alfa quando relaxado e 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 2.5: EEG da vigília

Sono NREM: Os quatro estágios do sono NREM são distinguíveis, principalmente, por alterações de padrões do EEG. Os dados recolhidos pelo EOG e pelo EMG contribuem muito pouco para a diferenciação dos estágios, exceto em casos específicos, como a transição do estágio 1 (onde ambos sinalizam) e 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 artefatos¹⁰, além de pequenas faixas de atividade teta.

¹⁰ Um artefato é um produto de arte mecânica. Neste caso, os artefatos são chamados ondas com vértices agudos.

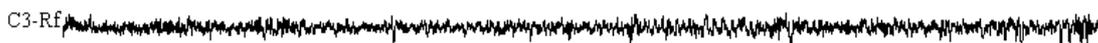


Figura 2.6: EEG em estágio 1

Estágio 2 : O padrão do EEG do estágio 2 reflete atividades de baixa voltagem e frequências mistas. Basicamente, a diferenciação, do estágio 2 para o estágio 1, dá-se 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 Hz com duração de 0.5 a 1.5 segundos, enquanto que, os complexos K são descritos como “ondas agudas negativas bem delineadas, imediatamente seguidas por um componente positivo” (Carshadon 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 2.7: 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 Hz com amplitudes maiores que 75 μ V de pico a pico por época (Carshadon e Rechtschaffen, 1994). Pode haver ocorrência de fusos e complexos K no estágio 3.



Figura 2.8: 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. Nesse estágio os olhos não se movem, e o EMG se encontra tonicamente ativo, embora tenha uma atividade considerada baixa.



Figura 2.9: EEG em estágio 4

Sono REM (ou PARADOXAL): 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 voltagem relativa baixa e frequências mistas.

Embora, essa fase se chame REM, o simples movimento dos olhos não é suficiente para indicar este estado do sono bastante particular. Segundo Carshadon e Rechtschaffen (1994), isso acontece uma vez que o fenômeno (REM) 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, só através do EEG, muitas vezes, é problemático diferenciar o padrão REM do estágio 2. Para que a época apresente a fase REM, além do EEG sinalizando o padrão específico, 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 frequências mistas entre dois fusos ou complexos-K é considerado estágio 2 se não houver a presença de movimento rápido dos olhos, ou movimentos estimulados neste intervalo e se o tempo deste intervalo for menor que 3 minutos” (apud Carshadon e Rechtschaffen, 1994, p.953).



Figura 2.10: EEG em estado REM

Com a intenção de simplificar as regras para o estagiamento do sono, expõe-se no Quadro 2.4 um resumo sobre os critérios descritos acima.

2.4.2 Progresso do Sono Durante a Noite

Segundo Carskadon e Dement (1994), o caso ideal de 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 toda noite em períodos de, aproximadamente, 90 minutos.

Quadro 2.4 – Regras para o Estagiamento do Sono

Fases	EEG	EOG	EMG
Vigília (relaxado)	- Olhos fechados : ondas alfa - Olhos abertos : baixa voltagem e frequências mistas	- Controle voluntário;	- Atividade tônica, relativamente alta; - movimento voluntário
NREM			
Estágio 1	- Relativa baixa voltagem - Frequências mistas - Apresenta ondas teta com altas amplitudes	SEM	- Atividade tônica fraca, podendo diminuir o estado de vigília
Estágio 2	- Baixa voltagem, - Frequências mistas - Presença de Fusos e Complexos K	SEM - ocasional próximo ao início do sono	- Atividade tônica fraca
Estágio 3	- $\geq 20\%$ e $\leq 50\%$ de ondas altas - Baixa amplitude	-	Atividade tônica fraca
Estágio 4	- $> 50\%$ de ondas altas - Baixa amplitude	-	Atividade tônica fraca
REM	- Baixa voltagem - Frequências mistas - Atividade teta e alfas lentas	REM	- Supressão tônica - Contração

2.4.2.1 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 pelos fusos de sono e 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 ocupam entre 20% e 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, seguido 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. Os movimentos ocorrem nas trocas de fases e nos estágios de sono mais superficiais (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 tende a encurtar na mesma medida, podendo, inclusive, desaparecer nos últimos ciclos, predominando o estágio 2 nestes casos.

O Quadro 2.5 mostra algumas características genéricas do sono normal de um jovem adulto, segundo Carskadon e Dement (1994).

Esse tipo de verificação é sempre realizado 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.

2.4.2.2 O Sono Normal em um Idoso

Segundo Tankova e Bucla-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.

Quadro 2.5 - Generalidades do sono normal de um jovem adulto

- ❑ O sono inicia-se pelo estado NREM.
- ❑ Os estados NREM e REM se alternam em períodos de 90 minutos aproximadamente.
- ❑ Ondas lentas predominam no primeiro terço da noite, e está ligado à iniciação do sono.
- ❑ O sono REM predomina no último terço da noite de sono, e está ligado ao ritmo circadiano da temperatura do corpo.
- ❑ O estágio 1 normalmente compreende de 1 a 5 % do sono.
- ❑ O estágio 2 normalmente compreende de 45 a 50 % do sono.
- ❑ O estágio 3 normalmente compreende de 3 a 8 % do sono.
- ❑ O estágio 4 normalmente compreende de 10 a 15 % do sono.
- ❑ Considerando os estágios, o sono NREM chega a atingir 80 % do sono.
- ❑ O sono REM compreende de 20 a 25 % do total do 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, tornando os idosos mais sensíveis a estímulos ambientais.

2.4.2.3 Características do sono REM

Em uma noite normal de sono, 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 que o indivíduo fica mais repousado durante a noite, a duração dos episódios de sono REM também aumenta (Guyton, 1993).

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

- ❑ Geralmente está associada ao sonho ativo;
- ❑ É mais difícil acordar indivíduos nesta fase do sono;
- ❑ Presença de tônus muscular por todo o corpo;
- ❑ A freqüência cardíaca e a freqüência respiratória se tornam irregulares;

- 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.

2.4.3 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 representa o tempo do sono, e o eixo x representa 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.

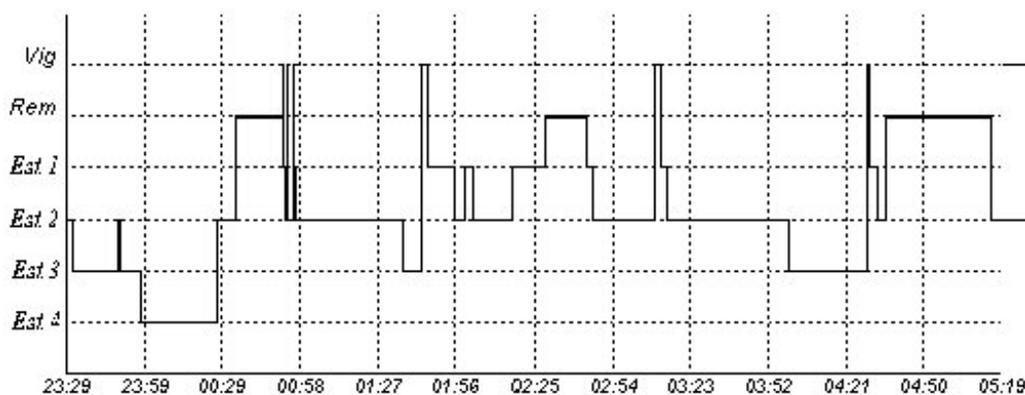


Figura 2.11 - Exemplo de hipnograma

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.

2.5 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 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):

Quadro 2.6 – 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 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 :

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

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.

Associados a outras afecções médicas : aqui encontra-se os problemas relacionados às 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.

2.6 O estagiamento

A polissonografia mostra uma sucessão de ondas cerebrais ordenadas e cíclicas de diferentes amplitudes e freqüências, de movimentos oculares e de mudanças de tono muscular que são utilizados para o estagiamento do sono. A seqüência das fases, a precisa cronologia dos eventos foi denominada arquitetura do sono. A arquitetura de uma noite de sono é representada através dos hipnogramas.

O estagiamento é realizado pela análise de no mínimo três canais polissonográficos e no máximo o limite do aparelho. Os sistemas computadorizados hoje, em uso, supriram o uso do papel e, registram com facilidade 30, 60 ou mais canais, caso o pesquisador necessite. O computador auxilia, também, no estagiamento, porém, ainda sem grande precisão (Martinez, 1999).

O estagiamento¹¹ do registro do sono é realizado, normalmente por conveniência, em segmentos chamados de épocas. O tamanho médio desses segmentos é de 15 a 40 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 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.

A aparência dos canais muda a cada instante. No curto período de uma época de 30 segundos, pode-se passar de vigília para estágio 1, para estágio 2 e retornar à vigília. A época recebe o rótulo da fase que predominar.

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 da fase da época em análise. Outros fenômenos, como a respiração e a saturação do oxigênio, também são apontados por Aserink e Kleitman (1953). Outros dados, anotados pelo técnico que acompanha o sono do paciente, também são utilizados no momento do estagiamento (Martinez, 1999)

2.6.1 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.

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 os especialistas. Dessa maneira, cada sono realizado em laboratório possui sua própria interpretação, e dentro deste contexto, as regras de Rechtschaffen e Kales têm funcionado mais como um guia do que propriamente como definições exatas.

¹¹ O padrão de estagiamento visual do sono segue critérios definidos por Rechtschaffen e Kales em 1968, que ainda são utilizados internacionalmente.

2.6.2 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 a fase REM e a fase Vigília. 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 visualmente. 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 têm 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, pode-se citar os classificadores baseados em Regras, em Análises Multidimensionais, em Análise Espectral, em Processamento de Sinal Digital (principalmente a FFT - *Fast Fourier Transform*¹²) em Sistemas Híbridos, em Classificadores Bayesianos, em Redes Probabilísticas, em matrizes de densidades espectral de cor, em Redes Neurais Artificiais e entre 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 al. (1998), entre as técnicas consideradas clássicas, a mais utilizada foi a técnica chamada de KNN (*k nearest neighbour*¹³). Outras técnicas também são citadas pela literatura, como o caso da análise multidimensional sobre o EEG, aplicada 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 são ainda exploradas para o estagiamento do sono, ou mesmo para o processamento de sinal. Pode-se citar como exemplo o estudo realizado por Berthomer, Prado e Benoit (1997), cujo trabalho propõe a

¹² Transformada Rápida de Fourier

¹³ Vizinhança mais próxima de k

utilização de filtros para analisar os canais de EEG. Os autores também apontam características que podem ser utilizadas como meio de detecção das fases do sono. Contudo, Bentrup e Ray (Sykacek et al., 1998) relatam que essas técnicas, em geral, possuem uma performance inferior as técnicas baseadas em Inteligência Artificial (IA).

Entre as técnicas baseadas em IA, os pesquisadores têm utilizado o aprendizado indutivo para construir árvores de decisão e classificadores baseados em regras, como é o caso de uma aplicação do C4.5¹⁴, relatado por Langley e Simon em 1995, e Kufrin 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 al. (1993) relata uma média de acerto em torno de 86 %. Outro exemplo da utilização de regras é o trabalho apresentado por Nielsen et al. (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 al. usou o estagiamento visual realizado por dois especialistas como referência. Os resultados obtidos por Nielsen tiveram uma concordância de 68% a 71%.

As redes neurais artificiais (RNA) 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 al. (1993) em testes realizados em uma população de 6 pacientes. Outro exemplo do uso de RNA 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. 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 têm 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

¹⁴ Ferramenta utilizada para construção de árvores de decisão e classificadores baseados em regras.

utilizou uma rede de Kohonen para produzir um semi-estagiamento semi-automático. Pode-se dizer semi-estagiamento uma vez que o trabalho de Lossmann não dividiu as fases conforme as definições recomendadas por Rechtschaffen e Kales (1968), mas segundo critérios próprios que reduz o número de fases.

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 elas são requisitos necessários para o tratamento do sinal proveniente do coletor digital. Pode-se citar, por exemplo, Baumgart-Schmitt et al. (1997), cujo trabalho utiliza algoritmos genéticos e algoritmos evolucionários para a otimização da rede neural. Os resultados alcançados por Baumgart-Schmitt et al. (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 Sykacek et al. (1998), cujos resultados apresentam uma performance de 82%. Segundo Sykacek et al. (1998), os bons trabalhos de estagiamento baseados em redes neurais têm apresentado performances que variam de 75% a 85 % de acerto.

Também se encontram 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. Pode-se citar o trabalho de Hadjiyannakis et al. (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 difusa, que apresenta uma taxa de acerto em torno de 50 %.

2.7 O Mercado

Comercialmente, o mercado é suprido por diversos equipamentos de polissonografia 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.

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, destaca-se o “*Nightingale Polygraphic Sleep Analyser*”, da empresa dinamarquesa “*Judex Datasysteme*”, 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 combinando aos 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 EUROMED¹⁵ (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.

¹⁵ O Projeto EUROMED é financiado pela Comissão Européia DG III, e tem por objetivo o desenvolvimento de sistemas na área de medicina (WWW_01, 1999).

2.8 Conclusão

A pesquisa sobre o sono está expandindo e atraindo cada vez mais a atenção dos cientistas. Os pesquisadores sabem, agora, que: o sono é um estado ativo e dinâmico; tem grande influência no dia a dia das pessoas; e que se deve entender o sono para poder entender um pouco mais sobre o cérebro humano. Técnicas inovadoras, tal como imagens do cérebro, podem agora ajudar os pesquisadores a entender melhor como regiões diferentes do cérebro funcionam durante o sono e como atividades distintas e desordens afetam o sono. O entendimento dos fatores que afetam o sono normal e o sono anormal pode levar a terapias novas e revolucionárias para o tratamento das desordens do sono e para modos de superar os problemas de reflexos atrasados e problemas associados às mudanças de trabalho. Pode-se esperar estes e muitos outros benefícios das pesquisas que permitirão o verdadeiro entendimento do impacto do sono na vida das pessoas.

Segundo Martinez¹⁶ (1999), os grandes desafios para a ampla utilização dos conhecimentos da especialidade do sono em prol da saúde da população, são:

- **Primeiro desafio:** Provar que a medicina do sono é uma parte legítima da melhor medicina.
- **Segundo desafio:** Modificar a cultura médica. Os médicos não estudaram sobre o sono na faculdade ou estudaram-no como uma função fisiológica e não como uma fonte de moléstia. Todos os pacientes dormem ou pelo menos deveriam dormir, então todo médico deve levar isto em consideração quando está analisando seu paciente.
- **Terceiro Desafio:** Modificar a cultura de quem padece de distúrbio do sono. Hoje, predomina o conceito de que seu sofrimento será permanente. Os pacientes, depois de resolvido o distúrbio e sono, reconhecem a importância de tais médicos. A sabedoria popular ainda não incorporou que o ronco e a insônia são doenças e têm tratamentos, de que a sonolência diurna não é preguiça e de que dirigir com sono pode matar.
- **Quarto desafio e principal:** Tornar a medicina do sono lucrativa. O motivo central para o lento avanço da especialidade em todo mundo, ainda mais no Brasil, é que

¹⁶ Martinez está envolvido com a prática da medicina do sono desde 1982. Ele se preocupa com o lento progresso da especialidade do sono.

ela gera déficit. Nos EUA, no Canadá e na Europa laboratórios de sono estão desativando leitos. No Brasil, diversos médicos vão para o exterior aprender, investem num laboratório e depois fecham devido ao prejuízo financeiro. Sem o apoio de instituições hospitalares e de universidades os maiores centros de pesquisa e laboratórios desapareceriam. Os sistemas de diagnósticos portáteis de baixo custo são uma possibilidade de expansão dos laboratórios. A qualidade dos traçados e a automatização do estagiamento, porém, ainda necessita melhorar.

3

Processamento de Sinal Digital

3.1 Introdução

Uma das características da era tecnicista é a presença de sinais, seja na forma elétrica, acústica, eletromagnética, ótica, entre outras.

O **Processamento de Sinal Digital** (DSP – *Digital Signal Processing*) é uma área distinta das outras áreas da ciência pelo único tipo de dado que usa: sinais. Na maioria dos casos, estes sinais são dados sensórios do mundo real: imagens visuais, ondas de som, vibrações, sinais elétricos, entre muitos outros. Os DSP são as técnicas matemáticas e os algoritmos usados para manipular os sinais após eles terem sido convertidos na forma digital (Smith, 1998). Isso inclui uma ampla variedade de objetivos, tal como: intensificação de imagens visuais, reconhecimento e geração de voz, compressão de dados para armazenagem e transmissão.

Antes do advento do computador, o processamento de sinais era feito exclusivamente de forma analógica, isto é, atuando sobre o sinal no seu nível físico. Com o computador tornou-se possível a realização muito rápida de um número muito grande de operações aritméticas. Então, alimentando um sistema digital de computação com números que representam um sinal, pode-se fazer com que o sistema manipule a representação do sinal, e não a sua realização física, para gerar a representação de um novo sinal.

O processamento dos sinais digitais é, portanto, o resultado da fusão entre duas tecnologias preexistentes: o processamento de sinais *lato sensu*, anteriormente realizado apenas por meios físicos; e as operações aritméticas com números, notadamente a adição e a multiplicação, já conhecidas e praticadas desde os primórdios da civilização.

O domínio da tecnologia do processamento dos sinais digitais depende, então, da análise matemática da representação através de seqüências de números, das propriedades destas seqüências, das técnicas para a sua manipulação, do estudo de algoritmos que realizam estas operações com o mínimo esforço computacional.

Algumas vantagens desta junção são evidentes, enquanto outras estão se revelando a cada dia que passa através do surgimento de novas tecnologias. Trabalhando com os sinais digitais é possível construir sistemas rápidos e com grande flexibilidade. Isso tem levado à crescente aplicação do processamento de sinais digitais em campos bastante variados como o processamento da voz, as telecomunicações, os sistemas de radar, sensoriamento remoto, a análise de sinais biomédicos.

Existem na literatura inúmeras técnicas que trabalham esses sinais, como: os filtros (lineares, estatísticos, gradientes), as transformadas (Fourier, wavelet, Laplace), as técnicas de extração de característica e de classificação (Schowengerdt, 1997; Gomes e Velho, 1994; Pandya e Macy, 1995).

Porém, existem sinais que apresentam uma alta complexidade e que necessitam de novas abordagens de processamento para serem entendidos e utilizados com maior eficiência. Um destes sinais, o que será explorado nesta tese, são os sinais do eletroencefalograma (EEG), que apresentam grande utilidade na área médica.

O DSP é uma das tecnologias mais poderosas que formará a ciência e a engenharia do século XXI (Smith, 1998). Revolucionárias mudanças já foram feitas em muitos campos: comunicação, imagens médicas, radar e sonar, reprodução de músicas com alta fidelidade, e exploração de petróleo, somente para citar algumas. Cada uma destas áreas tem desenvolvido uma tecnologia, com seus próprios algoritmos e técnicas matemáticas específicas. É impossível para um indivíduo dominar toda a tecnologia e todas as aplicações que foram desenvolvidas. O aprendizado sobre DSP envolve duas etapas: a aprendizagem dos conceitos genéricos que se aplicam em todos os campos, e a aprendizagem especializada das técnicas para áreas específicas de interesse. Este capítulo apresentará apenas uma visão genérica e superficial sobre as operações em DSP, a sua evolução e algumas aplicações.

3.2 Sinal Digital e o Processamento

A interação dos seres humanos (ou, mais genericamente, dos seres vivos) com o meio se baseia em diversos tipos de sinais, que são medidos, processados, analisados, e dão origem a decisões (Restivo, 1998). Os sinais luminosos permitem a visualização do meio ambiente; os sinais sonoros permitem a percepção auditiva e propicia a utilização da comunicação falada; os sinais eletromagnéticos abrem as portas para o fantástico mundo das telecomunicações.

Por um **sinal** entende-se qualquer variável que carrega ou contém alguma espécie de informação que pode, por exemplo, ser convertida, exibida ou manipulada (Restivo, 1998). Exemplos de tipos de sinais são:

- voz, que se encontra por exemplo no telefone, rádio;
- sinais biomédicos, tal como o eletroencefalograma;
- som ou música, tal como o reproduzido por aparelhos de CD (*compact disc*);
- vídeo ou imagem;
- sinais de radar, que são usados, por exemplo, para determinar alvos.

Com o advento do computador, e sua presença crescente no controle de diversos processos do cotidiano humano, cresceu a importância da representação e do processamento de sinais em forma digital. Essa representação tem um papel relevante em muitos campos, como já citado anteriormente.

O **processamento de sinal digital** é definido como a representação digital dos sinais e o uso dos processadores digitais para análise, modificação ou extração de informação dos sinais (Ifeachor e Jervis, 1995). A maioria dos sinais naturais é analógica em forma, significando, freqüentemente, que eles variam continuamente no tempo, e representam as variações de quantidades físicas, tal como, as ondas do som. Os sinais usados na forma mais popular de DSP são derivados de sinais analógicos, Esses são amostrados em intervalos de tempo regulares e convertidos na forma digital.

A função do processador de sinais digitais é a mesma do processador de sinais analógicos, mas sua implementação é muito diferente. Os processadores analógicos são implementados usando circuitos eletrônicos ativos ou passivos, e operam sobre ondas

contínuas. Os processadores digitais, por outro lado, são implementados usando um circuito lógico digital ou um programa de computador. Operam sobre uma seqüência de números obtidos pela amostragem da onda contínua ou do próprio meio. O uso dos processadores de sinais digitais, hoje, é muito amplo devido à grande disponibilidade de computadores. Além disto, um programa de computador pode ser escrito para implementar quase todas as espécies de processadores, como os filtros digitais (Tompkins, 1995).

3.3 Vantagens e Desvantagens do DSP

As razões específicas para processar um sinal digital podem ser, por exemplo, para remover interferências ou ruídos do sinal, para obter o espectro dos dados, ou para transformar os sinais numa forma desejada. O DSP é usado em muitas áreas, como naquelas em que os métodos analógicos foram previamente usados ou em aplicações inteiramente novas, onde os métodos analógicos são difíceis ou impossíveis de serem utilizados. A atração do DSP segue de vantagens importantes, como (Ifeachor e Jervis, 1995; Tompkins, 1995):

- *Acurácia garantida:* A acurácia é determinada a partir do número de bits usados.
- *Reprodutibilidade Perfeita:* O desempenho idêntico de unidade para unidade é obtido desde que não exista nenhuma variação em relação às tolerâncias de componentes. Por exemplo, usando técnicas de DSP, um registro digital pode ser copiado ou reproduzido diversas vezes sem qualquer degradação na qualidade do sinal.
- Nenhum desvio no desempenho com temperatura e idade. Esta é uma característica importante em aplicações médicas onde a maioria dos sinais tem baixas frequências que podem ser distorcidas devido à deterioração no circuito analógico.
- *Maior flexibilidade:* os sistemas DSP podem ser programados e reprogramados para realizar uma variedade de funções, sem modificar o hardware. Esta é talvez uma das características mais importantes do DSP.
- *Desempenho superior:* O DSP pode ser usado para desempenhar funções impossíveis com processadores de sinais analógicos. Por exemplo, a resposta de fase linear pode ser encontrada, e algoritmos de filtros adaptativos complexos podem ser implementados usando técnicas de DSP.

- Em alguns casos a informação pode já estar na forma digital e o DSP oferece a única opção viável.

O DSP também apresenta algumas desvantagens. Contudo, o significado dessas desvantagens está sendo continuamente diminuído por novas tecnologias (Ifeachor e Jervis, 1995; Smith, 1998).

- Tempo do projeto: a menos que se tenha um bom conhecimento sobre as técnicas de DSP e tenham-se recursos necessários (como bons software), o projeto de um DSP pode consumir muito tempo ou até ser impossível. A falta de profissionais nesta área é reconhecida amplamente. Contudo, a situação está mudando: alunos de graduação estão sendo informados sobre DSP e sistemas comerciais estão começando a explorar as vantagens do DSP em seus produtos.
- Em situações reais, considerações econômicas significam freqüentemente que os algoritmos de DSP são implementados usando somente um número limitado de bits. Em alguns sistemas de DSP, se, um número insuficiente de bits é usado para representar as variáveis, pode resultar em uma degradação séria no desempenho do sistema.

3.4 Evolução

Os modelos matemáticos básicos dos sinais e sistemas contínuos remontam ao século XIX, com as transformadas de Laplace e de Fourier.

Jean Baptiste Joseph Fourier nasceu em Auxerre, França, em 1768 e morreu em Paris em 1830. Um dos maiores matemáticos de todos os tempos. Estudou a teoria matemática da condução do calor, tendo estabelecido, no monumental tratado *Théorie Analytique de la Chaleur*, que publicou em 1822, a equação das derivadas parciais que governam o fenômeno e obteve a solução usando o desenvolvimento em série das funções trigonométricas. Os seus trabalhos contribuíram para muitas áreas da matemática, ciência e engenharia.

Pierre Simon, Marquês de Laplace, o maior astrônomo teórico depois de Newton, nascido vinte anos antes de Fourier, aplicou os seus conhecimentos matemáticos ao estudo

dos movimentos planetários, dando origem à hoje designada transformada de Laplace, que cedo encontrou aplicação em muitas outras áreas científicas, como processamento de sinais.

Também, De Moivre, que em 1730 introduziu a hoje chamada transformada em z , deve ser creditado como um dos precursores do processamento de sinal digital.

No entanto, é ao advento dos computadores digitais, verificado nos anos 40, que se deve o nascimento do DSP como disciplina. Nos anos 50, Shannon e Bode, dos Laboratórios “Telefone Bell” e “Linville” no MIT, foram certamente os primeiros a equacionar a utilização de computadores em processamento de sinal (Restivo, 1998). No início dos anos 60, Kaiser, no laboratório Bell, apresentou importantes contribuições para a análise e a síntese de filtros digitais. A transformada rápida de Fourier (FFT) foi ‘descoberta’ em 1965 por Cooley e Tukey, apesar da sua origem, algumas vezes, ser atribuída aos matemáticos alemães Runge e mesmo Gauss. A publicação, em 1975, dos livros referência (Oppenheim e Schaffer, 1975) e (Rabiner e Gold, 1975) marca verdadeiramente o nascimento de DSP como disciplina e os seus autores como os seus verdadeiros criadores.

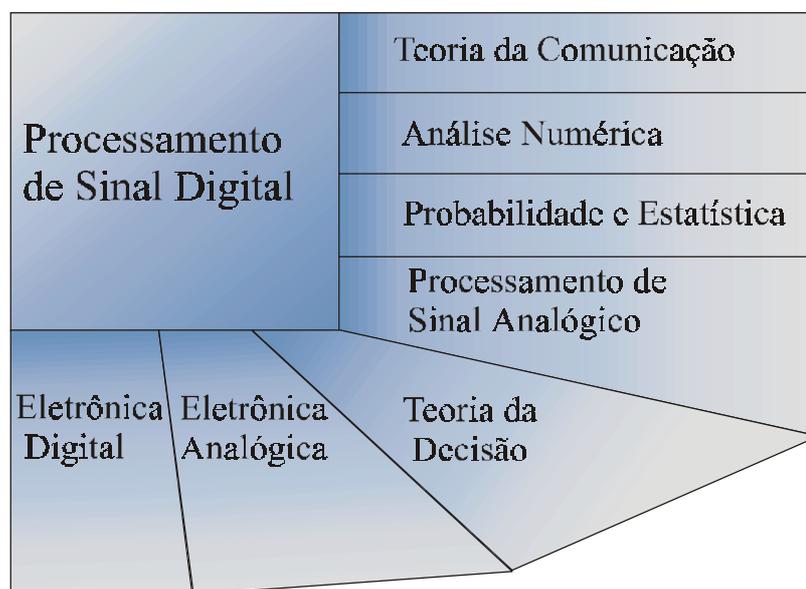
As raízes do DSP estão nos anos de 1960 e 1970 quando os computadores digitais tornaram-se disponíveis. Os computadores eram extensivamente caros nesta época, e o DSP era limitado somente a algumas poucas aplicações críticas. Os esforços pioneiros foram feitos em quatro áreas chaves: radar e sonar; onde a segurança nacional estava em risco; exploração de petróleo, onde grande volume de dinheiro poderia ser obtido; exploração espacial, onde os dados são insubstituíveis; e imagens médicas, onde vidas poderiam ser salvas (Smith, 1998).

A revolução do computador pessoal dos anos de 1980 e 1990 causou uma explosão de novas aplicações para o DSP. Além de ser motivada por necessidades militares e governamentais, o DSP foi guiado por aplicações comerciais. Os que apostaram no crescimento da área foram surpreendidos como vendedores de produtos que utilizam técnicas de DSP. O DSP alcançou o público em muitos produtos, tais como: telefones celulares, aparelhos de CD (*Compact Disc*) e correio eletrônico com voz.

Atualmente, o DSP emergiu de aplicações militares, onde nasceu, e desempenha um papel chave em produtos de consumo, industriais e de telecomunicações. Microprocessadores de sinal de baixo custo são componentes essenciais de jogos eletrônicos, telefones celulares, brinquedos, leitores de CDs, discos de computadores, modems, impressoras, sistemas de reconhecimento de voz e de vídeo conferência, e muitos outros produtos familiares. Cada vez

mais aplicações, tradicionalmente do domínio dos sistemas analógicos, estão encontrando soluções digitais mais baratas e mais fiáveis.

O DSP é o resultado de mudanças revolucionárias em muitas áreas adjacentes. O DSP é muito interdisciplinar. Como a Figura 3.1 sugere, os limites entre DSP e outras disciplinas técnicas (como a teoria da comunicação e análise numérica) não são bem definidas, mas ao invés disso são difusas e com sobreposição. Se desejar especializar-se em DSP, essas áreas são aliadas e pode ser útil estudá-las também. Hoje, o DSP é uma ferramenta básica que os engenheiros e cientistas necessitam em muitos campos.



*Figura 3.1: Os limites entre o DSP e outras áreas de ciências, engenharias e matemática é difusa e com sobreposição
Fonte: Adaptado de (Smith, 1998)*

3.5 Áreas de Aplicação

O DSP é um dos campos de pesquisa mais crescente em eletrônica moderna sendo usado em qualquer área onde a informação é manuseada em uma forma digital ou controlada por um processador digital. As áreas de aplicação incluem (Ifeachor e Jervis, 1995; Smith, 1998):

- Processamento de Imagens:
 - Reconhecimento de padrões
 - Robótica
 - Animação

- Mapas de satélites
- Controle/ Instrumentalização
 - Análise de espectro
 - Posição e taxa de controle
 - Redução de ruído
 - Compressão de dados
- Voz/Áudio
 - Reconhecimento de voz
 - Síntese de voz
 - Texto para voz
 - Áudio digital
 - Equalização
- Militar
 - Comunicação segura
 - Processamento de radar
 - Processamento de sonar
 - Direção de projétil
 - Detecção de alvo
- Telecomunicações
 - Cancelamento de eco
 - Equalização adaptativa
 - Vídeo conferencia
 - Comunicação de dados
- Biomédica
 - Monitoramento de paciente
 - Mapeadores do cérebro EEG
 - Análise de ECG
 - Intensificação/armazenagem de raio-x

Essa lista, que com certeza não está completa, confirma a importância do DSP.

3.6 Elementos em DSP

Esta seção descreve alguns dos elementos básicos em DSP, necessários para o entendimento das próximas seções.

Tempo e Freqüência: Um sinal pode ser estudado sob dois pontos de vista: do domínio do tempo e do domínio da freqüência.

O domínio do tempo é mais usado. Esse é semelhante a um traçado de um osciloscópio onde a deflexão vertical é a amplitude do sinal e a deflexão horizontal é a variável tempo.

O domínio da frequência é semelhante a um traçado de um analisador de espectro, onde a deflexão horizontal é variável frequência e deflexão vertical é a amplitude do sinal em função da frequência.

Qualquer sinal dado pode ser completamente descrito em ambos os domínios. Pode-se converter um sinal de um domínio para outro através da transformada de Fourier (mais detalhes no capítulo 4).

Sistema: Um sistema é qualquer processo que produz um sinal de saída em resposta a um sinal de entrada (Smith, 1998). Isto é ilustrado na Figura 3.2. Nos sistemas discretos os sinais de entrada e saída são discretos, tal como os programas computacionais que manipulam valores armazenados em matrizes.



Figura 3.2: Esboço de um sistema discreto

Um sistema pode ser linear ou não linear. Como exemplo de sistemas lineares tem-se: os filtros lineares, a convolução, diferenciação e integração e mudanças no sinal (ecos, ressonâncias,...); e como sistemas não lineares, pode-se citar: filtros não lineares e a multiplicação de dois sinais (como na modulação por amplitude).

Impulso: Impulso é um sinal composto de zeros exceto em um ponto. O impulso unitário, mais conhecido como função Delta Dirac e o mais utilizado, é definido como:

$$\delta(n) = \begin{cases} 1 & \text{se } n = 0 \\ 0 & \text{se } n \neq 0 \end{cases} \quad (3.1)$$

Impulso de Resposta: Como o nome sugere, o impulso de resposta $h(n)$ é o sinal que sai de um sistema quando a função de impulso é a entrada. Se dois sistemas são diferentes

produzirão impulsos de resposta diferentes. Se o sistema considerado é um filtro, o impulso resposta e chamado núcleo do filtro.

3.7 Operações Chaves em DSP

Existem muitos algoritmos de DSP e outros estão sendo inventados e descobertos. Contudo, todos esses algoritmos, incluindo o mais complexo, requerem operações básicas similares, tais como: convolução, correlação, filtros, transformações e modulação (Quadro 3.1). É importante ressaltar que todas estas operações requerem somente operações aritméticas simples de multiplicação, adição/subtração, e atrasos (deslocamentos ou translação).

3.7.1 Convolução

A convolução é uma das operações mais comumente usadas em DSP. O termo convolução descreve, entre outras coisas, como a entrada para um sistema interage com o sistema para produzir a saída. Geralmente, a saída do sistema será uma versão atenuada e atrasada ou ampliada da entrada.

Dados duas seqüências finitas e causais, $x(n)$ e $h(n)$, de comprimentos N_1 e N_2 , respectivamente, sua convolução é definido por:

$$y(n) = h(n) \otimes x(n) = \sum_{k=-\infty}^{+\infty} h(k)x(n-k) = \sum_{k=0}^{M-1} h(k)x(n-k), \quad n = 0, 1, \dots, (M-1) \quad (3.2)$$

onde o símbolo \otimes é usado para denotar a convolução e $M = N_1 + N_2 - 1$.

Um exemplo de convolução linear das duas seqüências esboçadas na Figura 3.3. Neste exemplo, $h(n)$ ($n = 0, 1, 2, \dots$) pode ser visto como uma resposta impulso de um sistema digital, e $y(n)$ a resposta do sistema para uma seqüência de entradas $x(n)$. Os valores numéricos para a convolução, isto é, $y(n)$, são obtidos pela avaliação direta da equação (1). Por exemplo, $y(i)$ é obtido como segue:

$$\begin{aligned} y(1) &= h(0)x(1) + h(1)x(0) + h(2)x(-1) + \dots + h(12)x(-11) = \\ &= 0 \times 1 + (-0.02) \times 1 + 0 \times 0 + \dots + 0 \times 0 = -0.02 \end{aligned} \quad (3.3)$$

Quadro 3.1 - Resumo das operações chaves em DSP e suas aplicações

Operação	Fórmula	Aplicação
Convolução	$y(n) = h(n) \otimes x(n) = \sum_{k=0}^{M-1} h(k)x(n-k)$ $n = 0, 1, \dots, (M-1)$	<ul style="list-style-type: none"> ▪ Construção de filtros (FIR e IIR)
Correlação	<ul style="list-style-type: none"> • cross-correlação $\rho_{xy}(n) = \frac{r_{xy}(n)}{[r_{xx}(0)r_{yy}(0)]^{1/2}} \quad n = 0, \pm 1, \pm 2, \dots$ onde: $r_{xy}(n) = \begin{cases} \frac{1}{N} \sum_{k=0}^{N-n-1} x(k)y(k+n) & n = 0, 1, 2, \dots \\ \frac{1}{N} \sum_{k=0}^{N+n-1} x(k-n)y(k) & n = 0, -1, -2, \dots \end{cases}$ $r_{xx}(0) = \frac{1}{N} \sum_{k=0}^{N-1} [x(k)]^2, \quad r_{yy}(0) = \frac{1}{N} \sum_{k=0}^{N-1} [y(k)]^2$ • auto-correlação $\rho_{xx}(n) = \frac{r_{xx}(n)}{r_{xx}(0)} \quad n = 0, \pm 1, \pm 2, \dots$ onde: $r_{xx}(n) = \frac{1}{N} \sum_{k=0}^{N-n-1} x(k)x(k+n) \quad n = 0, 1, 2, \dots$ 	<ul style="list-style-type: none"> ▪ Processamento de Imagens ▪ Sensoriamento Remoto ▪ Sistemas de Radar e Sonar ▪ Detecção e identificação de ruídos ▪ Engenharia de Controle ▪ Processo de Convolução
Filtros	$y(n) = \sum_{k=0}^{N-1} h(k)x(n-k)$	<ul style="list-style-type: none"> ▪ Remover ou reduzir ruídos ▪ Extrair informações ▪ Separar dois ou mais sinais, previamente combinados.
Transformadas	$X(k) = \sum_{n=0}^{N-1} x(n)W^{nk}, \quad \text{onde } W = e^{-j2\pi/N}$	<ul style="list-style-type: none"> ▪ Conversão entre os domínios de tempo e frequência, que permitem uma implementação mais eficiente dos filtros, convolução e correlação.
Modulação	<hr style="width: 10%; margin: 0 auto;"/>	<ul style="list-style-type: none"> ▪ Sinais que necessitam ser transmitidos sobre distâncias longas ▪ Telecomunicações ▪ Engenharia Audio-Digital

Os filtros fornecem um exemplo de aplicação de convolução. Eles podem ser projetados para “convoluir” seqüências ou realizar filtros digitais mais genéricos, como os filtros bidimensionais empregados em processamento de imagens (Gomes e Velho, 1994), redução de ruído em reconhecimento de padrões e intensificação de imagens.

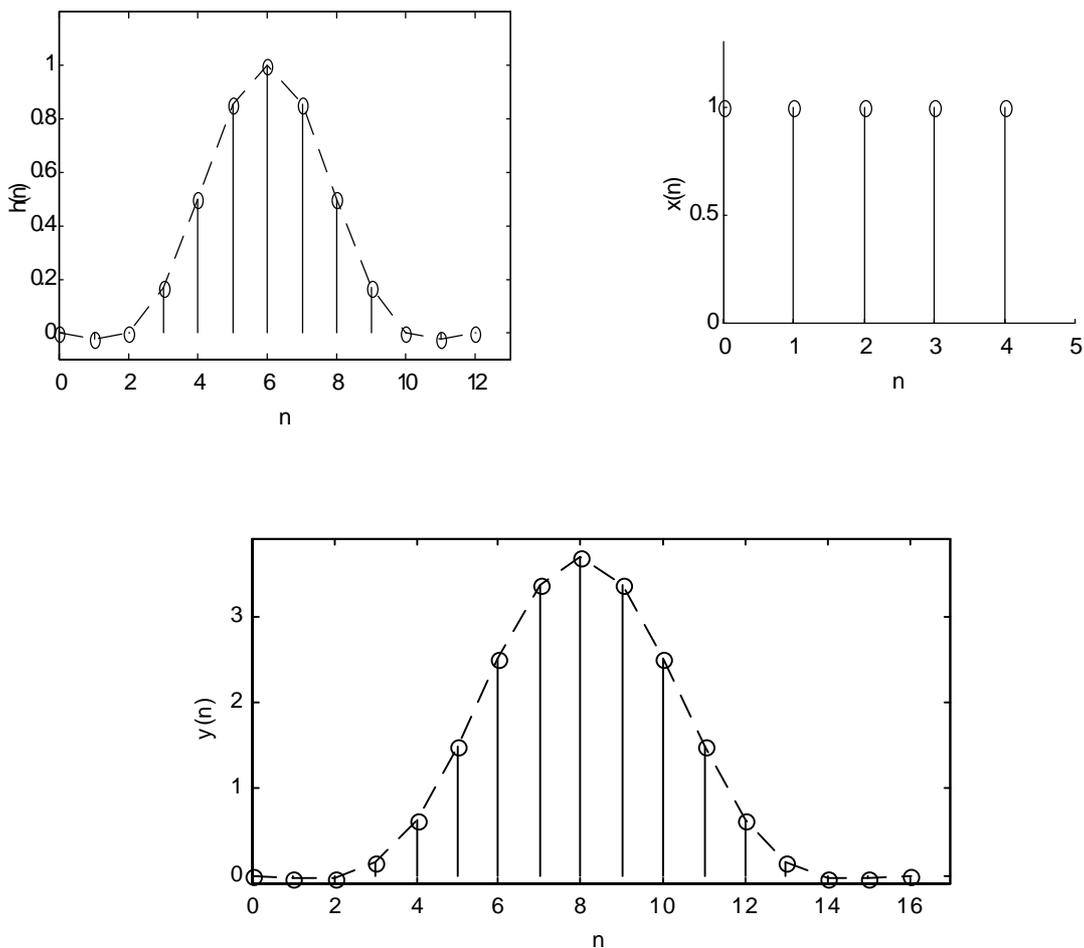


Figura 3.3: Um exemplo de convolução de duas seqüências. $y(n)$ é a convolução de $h(n)$ e $x(n)$

Fonte: Adaptado de Ifeachor e Jervis (1995)

3.7.2 Correlação

A correlação é freqüentemente necessária por ser capaz de quantificar o grau de interdependência de um processo sobre um outro, ou, estabelecer a similaridade entre um conjunto de dados e outro. A correlação pode ser definida matematicamente ou pode ser quantificada. O processo de correlação ocupa um lugar significativo em processamento de sinais. Existem duas formas de correlação: auto e cross-correlação.

A função da **cross-correlação** (FCC) é uma medida de similaridade entre dois sinais. As aplicações das FCC incluem análise cross-espectral e a recuperação/detecção de sinais descaracterizados por ruídos (como a detecção de sinais oriundos de radar).

Dadas duas seqüências de comprimento N , $x(k)$ e $y(k)$, com média zero uma estimativa da cross-correlação é dada por:

$$\rho_{xy}(n) = \frac{r_{xy}(n)}{[r_{xx}(0)r_{yy}(0)]^{1/2}} \quad n = 0, \pm 1, \pm 2, \dots \quad (3.4)$$

onde $r_{xy}(n)$ é uma estimativa da cross-variância e é definida como:

$$r_{xy}(n) = \begin{cases} \frac{1}{N} \sum_{k=0}^{N-n-1} x(k)y(k+n) & n = 0, 1, 2, \dots \\ \frac{1}{N} \sum_{k=0}^{N+n-1} x(k-n)y(k) & n = 0, -1, -2, \dots \end{cases} \quad (3.5)$$

onde:

$$r_{xx}(0) = \frac{1}{N} \sum_{k=0}^{N-1} [x(k)]^2, \quad r_{yy}(0) = \frac{1}{N} \sum_{k=0}^{N-1} [y(k)]^2. \quad (3.6)$$

A função de **auto-correlação** (FAC) envolve somente um sinal e fornece informação sobre a estrutura do sinal ou seu comportamento no mesmo domínio. É uma forma especial de FCC e é usado em aplicações similares. É particularmente útil na identificação de periodicidades escondidas.

Uma estimativa da auto-correlação, $\rho_{xx}(n)$, de uma seqüência de comprimento N , $x(k)$, com média zero é dada por:

$$\rho_{xx}(n) = \frac{r_{xx}(n)}{r_{xx}(0)} \quad n = 0, \pm 1, \pm 2, \dots \quad (3.7)$$

onde $r_{xx}(n)$ é uma estimativa da autocovariância e é definida como:

$$r_{xx}(n) = \frac{1}{N} \sum_{k=0}^{N-n-1} x(k)y(k+n) \quad n = 0,1,2,\dots \quad (3.8)$$

Um exemplo de auto-correlação pode ser visto na Figura 3.4.

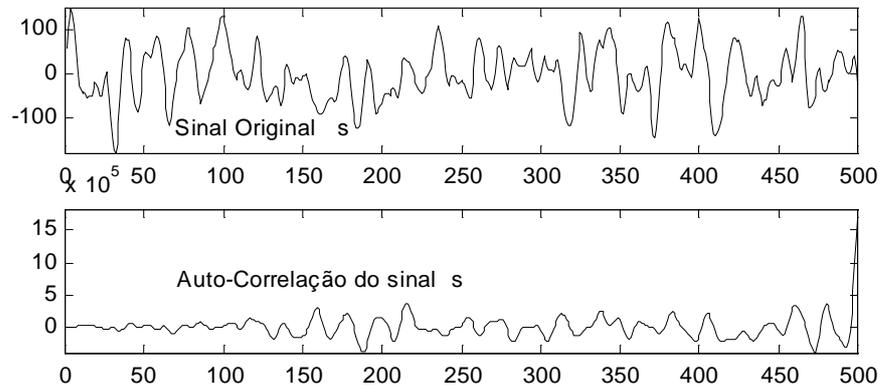


Figura 3.4 - Cross-Correlação do sinal s

Aplicações são encontradas em: processamento de imagens para visão de robô; sensoriamento remoto por satélites, no qual os dados de diferentes imagens são comparados; sistemas de radar e sonar para encontrar a posição e o alcance no qual as ondas transmitidas e refletidas são comparadas; na detecção e identificação de sinais em ruídos; em engenharia de controle para observar os efeitos das entradas sobre as saídas; e em muitos outros campos, como na climatologia.

A correlação é também parte integrante do processo de convolução. O processo de convolução é essencialmente a correlação de duas seqüências de dados no qual uma das seqüências foi invertida. Isso significa que os mesmos algoritmos podem ser usados para computar a correlação e a convolução, simplesmente pela inversão de uma das seqüências.

3.7.3 Filtros Digitais

Os filtros são algoritmos razoavelmente simples que podem ser implementados em software ou hardware e podem mudar um sinal para uma variedade de propósitos, incluindo: amoldar o sinal em uma forma satisfatória para transmissão ou armazenamento, remover ruído e distorções, extrair informações relevantes, separar dois ou mais sinais que foram previamente unidos, ou minimizar a interferência de outros sinais. Tais filtros parecem

virtualmente em todos os componentes de sistemas de comunicações e podem ser linear ou nonlinear (Madisetti, 2000).

O filtro digital é uma das operações mais importantes em DSP. As operações de um filtro digital, para uma classe importante de filtros, são definidas como:

$$y(n) = \sum_{k=0}^{N-1} h(k)x(n-k) \quad (3.9)$$

onde $h(k)$ ($k = 1, 2, \dots, N-1$) são os coeficientes do filtro, e $x(n)$ e $y(n)$ são, respectivamente, a entrada e a saída do filtro. Para um dado filtro, os valores de seus coeficientes são únicos e determinam as características do filtro.

Note que o filtro é de fato a convolução de um sinal e a resposta impulso do filtro no domínio do tempo, que é $h(k)$.

Devido à importância dos filtros nos sinais polissonográficos, o próximo capítulo apresentará o assunto com mais detalhes.

3.7.4 Transformadas Discretas

As transformadas discretas permitem a representação de sinais discretos no domínio de tempo ou no domínio de frequência, ou a conversão entre representações do domínio de frequência e tempo. O espectro de um sinal é obtido pela decomposição em seus componentes de frequência usando uma transformada discreta. Um conhecimento de tais espectros é inavaliável em, por exemplo, determinar a largura da banda requerida para transmitir um sinal. A conversão entre domínio de tempo e frequência é necessária em muitas aplicações de DSP. Por exemplo, permitem uma implementação mais eficiente dos filtros digitais, da convolução e da correlação.

Existem muitas transformações discretas, mas a Transformada de Fourier Discreta (DFT – *Discrete Fourier Transform*) é a mais usada e é definida como:

$$X(k) = \sum_{n=0}^{N-1} x(n)W^{nk}, \quad \text{onde } W = e^{-j2\pi/N} \quad (3.10)$$

A resposta de impulso do filtro, $h(n)$ ($n = 0, 1, \dots, N-1$) é transformado para resultar a resposta frequência do filtro usando DFT. Mais detalhes da DFT e suas aplicações podem ser visto em Smith (1998).

A transformada de Fourier é uma das mais utilizadas, porém existem outras transformadas importantes em DSP, como: transformada em z, cosseno e as wavelets.

Devido à importância das transformadas, em processamento de sinais digitais, o próximo capítulo fornecerá mais detalhes sobre elas.

3.7.5 Modulação

A modulação e a demodulação convertem o sinal para uma forma apropriada para a sua transmissão através de fibra óptica, cabo coaxial, linhas de telefone, ..., e re-convertem o sinal na chegada. Estes esquemas podem substituir métodos clássicos de rádio (modulação analógica como a AM e FM) por métodos modernos baseado em processamento de sinal estatístico que usa filtros emparelhados e detectores de correlação e demodulação de máxima verossimilhança que especificamente são engrenadas à transmissão de sinais digitais (modulação digital). A teoria e prática de modulação são aplicações maduras e bem entendidas, mas novas aplicações e dispositivos auxiliam para novas extensões e direções (Madisetti, 2000).

Os sinais digitais são raramente transmitidos sobre longas distâncias ou armazenados em grandes quantidades em sua forma original. Os sinais são normalmente modulados para assimilar suas características de frequência àquelas dos transmissores, para minimizar a distorção de sinais, para utilizar a largura da banda disponível eficientemente, ou para assegurar que os sinais tenham algumas propriedades desejáveis. Talvez as duas áreas de aplicação onde a modulação é extensivamente empregada são telecomunicações e engenharia áudio digital.

O propósito de um sistema de comunicação, por exemplo, é entregar um Sinal Mensagem de uma fonte de informação para outra, em uma forma identificável para o usuário final (destino), estando a fonte e o usuário separados fisicamente um do outro. Para que isto ocorra, o transmissor modifica o Sinal Mensagem para uma forma adequada de transmissão através do canal. Tal modificação é alcançada através de um processo chamado **modulação**. O processo de modulação envolve, freqüentemente, a variação de alguns parâmetros de um

sinal de alta frequência, conhecido como onda portadora, de acordo com o sinal que se deseja transmitir ou armazenar, chamado sinal modulante. O resultado da inferência de um sinal sobre outro é um terceiro sinal chamado sinal modulado.

Resumidamente pode-se definir “Modulação” da seguinte forma: *Modulação é um processo que consiste em se alterar uma característica da onda portadora proporcionalmente ao sinal modulante* (Maranhão, 1999).

O receptor recria o sinal modulante original. Essa recriação é acompanhada pelo uso de um processo conhecido como **demodulação** que nada mais é que o processo inverso da modulação usado pelo transmissor. Contudo, devido à inevitável presença de ruídos e distorção do sinal recebido, o receptor não pode recriar o sinal de mensagem exatamente. O resultado da degradação do sistema é influenciado pelo tipo de modulação usado.

Os três esquemas de modulação digital comumente usados para transmissão de sinais digitais sobre um canal de banda passante são: ASK (*amplitude shift keying*) ou Chaveamento de Amplitude, PSK (*phase shift keying*) ou Chaveamento de Fase e FSK (*frequency shift keying*) ou Chaveamento de Frequência.

Quando os dados digitais são transmitidos sobre uma rede toda digital, um esquema conhecido como modulação por código de pulso (PCM – *Pulse Code Modulation*) é comumente usado.

Diversos outros esquemas de modulação têm sido desenvolvidos para áudio digital.

3.8 A estatística e a probabilidade

A estatística e a probabilidade são usadas em DSP para caracterizar os sinais e os processos que os geram (Smith, 1998). Por exemplo, um uso primário em DSP é reduzir a interferência, o ruído, e outros componentes indesejáveis nos dados adquiridos. Estes podem ser uma parte inerente do sinal que está sendo medido, podem surgir de imperfeições no sistema de aquisição de dados, ou podem ser introduzidos como subproduto inevitável de alguma operação de DSP. A estatística e a probabilidade permitem que estas características indesejáveis sejam medidas e classificadas, o que seria o primeiro passo em estratégias de desenvolvimento para remover os componentes afetados.

3.9 O DSP em Sinais Biológicos

O vertiginoso desenvolvimento tecnológico da eletrônica, acoplado ao crescimento no conhecimento científico sobre as causas orgânicas das doenças humanas neste final de século, possibilitou um grande desenvolvimento de novos equipamentos e técnicas diagnósticas e terapêuticas na Medicina (Sabbatini, 1997). Tudo começou na década 20, quando surgiu o primeiro eletrocardiógrafo, e em seguida, na década 30, o eletroencefalógrafo. Ambos revolucionaram a cardiologia e a neurologia, respectivamente, e introduziram um novo conceito na esfera médica: o sinal biológico. Por exemplo, o ECG caracteriza a evolução temporal dos potenciais de ativação elétrica do tecido muscular cardíaco, o EEG caracteriza a evolução temporal da somatória dos potenciais de membrana dos neurônios encefálicos, etc.

O organismo "emite" sinais das mais variadas naturezas; somente alguns dos quais têm valor diagnóstico, por refletirem, de forma inconspícuas, diversas alterações patológicas do órgão ou sistema em que ocorrem. Alguns variam no tempo de forma lenta (por exemplo, a temperatura interna), outras de forma muito rápida (por exemplo, a vibração das cordas vocais). Além disso, a energia física envolvida em um sinal biológico pode ser de natureza elétrica (como o ECG e o EEG) ou não elétrica (térmica, mecânica, entre outras).

O processamento digital dos sinais biológicos oferece muitas vantagens e uma maior flexibilidade em relação aos sistemas analógicos. Como, após o processo de conversão A/D (Analógico/Digital), um sinal temporal passa a ser representado por um conjunto de valores numéricos discretos na memória do computador, é muito fácil e conveniente realizar diversas manipulações e transformações matemáticas sobre esse conjunto de números. Assim, diversas funções que só podem ser conseguidas por meio de circuitos eletrônicos caros e especializados em sistemas de registro analógico, são obtidas e simuladas sem dificuldades por meios puramente lógicos (por software ou programas especializados de computador). Algumas dessas funções são (Sabbatini, 1997):

- Filtragem de ruídos (eliminação de interferências de baixa ou alta frequência, tais como artefatos de movimento, cabos mal conectados, influência da rede elétrica comum, etc.)
- Amplificação (aumento da amplitude absoluta do sinal), integração (soma cumulativa de variações) e diferenciação (medida da velocidade de variação). Por exemplo: dar

um *zoom* na imagem de um sinal, de modo a detectar variações minúsculas da linha de base, como no ECG de alta resolução; etc.

- Obtenção das frequências sinusoidas puras, ou harmônicas, que integram um sinal complexo. Essa análise, denominada de espectral ou de Fourier, permite isolar componentes de significado fisiológico em um sinal, tais como as ondas alfa, beta, gama e delta em um EEG, ou as periodicidades de flutuação da frequência cardíaca registrada em longo prazo, etc.
- Síntese de algumas formas de registro a partir de outras: por exemplo, um vetocardiograma pode ser obtido a partir de um registro de ECG simples de três derivações (sem necessidade de comprar um vetocardiógrafo.); ou o mapeamento espacial de sinais, como, por exemplo, a topografia cerebral de EEG.
- O reconhecimento e interpretação automática de sinais, como os novos equipamentos de ECG que são capazes de realizar, automaticamente, diversas medidas de amplitude, duração, e propor interpretações diagnósticas com grande acurácia.

Além disso, um sinal biológico digitalizado pode ser armazenado de forma econômica, na forma de arquivos de computador; pode ser transmitido confiavelmente através de linhas telefônicas e de rádio, não importa a que distância; pode ser exibido e impresso de inúmeras formas e maneiras. Um registro médico computadorizado, por exemplo, pode incorporar diretamente sinais biológicos digitalizados. Assim, ao solicitar ao computador que mostre os últimos dez ECG de um paciente, por exemplo, o sistema poderá recuperá-los a partir dos arquivos onde foram gravados e exibi-los no vídeo ou na impressora.

Usando uma placa de conversão A/D (Analogico/Digital) adequada (já disponível no mercado nacional, a um preço relativamente baixo), e um conjunto de softwares genéricos para processamento digital de sinais, como o LabView for Windows, é possível transformar um simples microcomputador PC em um instrumento biomédico universal, reunindo vários tipos em um, como por exemplo, um ECG, um EEG, um EMG, um espirômetro/fluxômetro respiratório, medidor não invasivo de pressão arterial, entre outros. Não é preciso dizer a redução de custos a que isto levará.

Alguns aparelhos de polissonografia além de fazer o registro dos sinais de vários canais de EEG, EMG e EOG, realizam o estagiamento automático do sono. Embora os

resultados deste estagiamento ainda não sejam confiáveis, já auxilia muito o estagiador. Ainda tem-se os aparelhos de polissonografia portáteis, sem custos para a clínica com hotelaria e um técnico para acompanhar o paciente. Para o paciente tem-se o conforto de sua casa. Esses aparelhos ainda não fornecem dados satisfatórios, mas com certeza este problema será superado com os avanços tecnológicos (Martinez, 1999).

3.10 Conclusões

Apesar do assunto ser DSP – processamento de sinal digital- não se pode esquecer que, as informações são transformadas em sinais para serem distribuídas através das linhas telefônicas, antenas, satélites, fibra óptica (internet), e mais recentemente por ondas (como o laser). Segundo Ackenhusen (1995), pode-se considerar o processamento de sinais como a conversão de grandes quantidades de dados em formas concentradas de informação. Muitas das coisas que a população desfrutam hoje, desde a música que ouvem em um *CD-player* até os sistemas biomédicos que salvam vidas, dependem da tecnologia sobre processamento de sinais.

Diversos avanços importantes em DSP, nas últimas décadas, tal como modulação, compressão de sinal, correção de erro, ajudaram a tornar possível o mundo Web, o ensino a distância, o celular, TV a cabo, entre outros. Contudo, devido à maturidade de muitas idéias-chaves nessa área, as pesquisas no futuro provavelmente se bifurcarão em avanços comerciais práticos e a elaboração de projetos para mover a tecnologia de refinamento para desenvolvimento difundido, e a procura por abordagens fundamentalmente novas e diferentes para produzir idéias novas (Madisetti, 2000).

As áreas que serão favorecidas com novas aplicações comerciais são: sonar e radar, comunicação, telecomunicação, biomédica, internet, ensino a distância, e a educação como um todo.

Novas formas de compressão de informação serão buscadas, pois as técnicas que existem, apesar de terem provado ter sucesso, são técnicas específicas para determinadas tarefas. Uma das técnicas que será explorada é a teoria das Wavelets. Também será necessário o desenvolvimento de chips altamente velozes e processadores especiais para todos os aspectos de compressão, incluindo decomposição de sinais, clusterização e quantização.

Dentre as diversas tendências de pesquisas que estão emergindo em DSP, pode-se citar: a extração de informação, a redução de informação e a reprodução de funções cognitivas humanas.

Os modelos são chaves para a extração de informação dos dados. Alguma suposição do processo subjacente que produziu a informação, combinados com a identificação de um modesto número de parâmetros que governam o modelo em um particular momento no tempo, forma a base das técnicas de estimação que buscam minimizar o erro entre o sinal real e o sinal gerado a uma colocação particular de parâmetros do modelo (Ackenhusen,1995). Nesta linha, estudos que aplicam estimação espectral de ordem mais alta estão emergindo, generalizando a representação de segunda ordem de espectro potencial. Similarmente, o uso de algoritmos que são baseados em dinâmica não linear, incluindo sistemas caóticos e modelos fractais auto-similares, estão se tornando ferramentas com objetivo de extrair informações.

Outro conceito pertencente à extração de informação de dados é o efeito de redução de informação (Ackenhusen,1995). Os algoritmos de processamento de sinais tipicamente começam com uma fonte de dados alta como entradas (exemplo, sinal de voz ou seqüência de imagens), e então aplicam operações sucessivas para destacar partes da informação características e eliminar as partes com ruídos ou redundantes, resultando em uma redução na taxa de informação transferida. A nova direção é a busca por novas técnicas de quantização de informação. O vetor de quantização reduz a taxa de informação por quantizar um grupo de amostras, ou sua representação espectral, por substituí-lo com o vizinho mais próximo escolhido de um dicionário pré-computado e transmitindo somente o índice codebook da escolha. Outra linha é o processamento simbólico, através do qual a informação sinal é representada por símbolos, o que permitir o raciocínio na presença de incertezas e tomar decisões de classificação em face de fontes múltiplas freqüentemente contraditórias de evidências.

Como sugerido pelas considerações dos modelos e redução de informação, a terceira tendência nesta área é a ênfase sobre a reprodução de certas funções cognitivas humanas (Ackenhusen,1995). Isto é muito aparente nas aplicações de processamento de sinais de reconhecimento de voz e reconhecimento de caracteres, mas é importante também na detecção de ruídos nos sinais, para o qual os modelos são usados que estão em sintonia com

processos humanos. Medidas de similaridade (distância) baseadas na percepção são usadas em algoritmos para alocar bits de um modo que minimiza a distorção como percebido pelos humanos. Diversos esforços têm emergido para fornecer objetivos correlatos para critério perceptual, permitindo uma prescrição computacional para substituir o papel humano de avaliadores de informação. Modelos de linguagens humanas, faladas e escritas, são contribuições importantes para o desempenho acurado de reconhecimento automático.

4

Transformadas e Filtros Digitais

As transformadas e os filtros digitais são duas operações muito importantes no processamento de sinais biológicos. As transformadas permitem a conversão dos dados para domínios diferentes, como a transformação do domínio do tempo para o domínio da frequência e vice versa. Os filtros, por outro lado, permitem a remoção de ruídos e a suavização dos dados.

4.1 Transformadas

Uma transformação linear $T: S \rightarrow S'$ entre dois modelos funcionais distintos de um espaço de sinais é chamada transformada (Gomes, 1994). Em geral, exige-se que essa transformação seja inversível, de modo a possibilitar uma conversão completa entre dois modelos funcionais. Os dois modelos fornecem informações complementares sobre os mesmos dados. Um exemplo importante de transformada é a transformada de Fourier. Esta transformada relaciona o modelo espacial com o modelo espectral de sinais, fornecendo informações sobre as frequências presentes em cada sinal. O uso das transformadas permite a mudança entre diversos modelos de sinais de modo a obter um modelo mais adequado à solução de determinado problema. Uma transformada pode ser contínua ou discreta dependendo do domínio do sinal ser discreto ou contínuo.

As transformadas discretas, especialmente a transformada discreta do co-seno, são usadas na compressão de sinais de voz e vídeo para permitir a transmissão com largura de banda reduzida (Gomes, 1994). Elas são também utilizadas em processamento de imagens

para obter um conjunto reduzido de características nos casos de reconhecimento de padrões. As transformadas são também úteis como ferramentas matemáticas para a aceleração de cálculos em outras aplicações em processamento de sinais, tais como, correlação, como a usada em sonares para detecção de intervalos, ou em convolução ou deconvolução para determinar a inter-relação entre um sistema e suas entradas e saídas. Para estes cálculos as transformações do domínio da frequência para o domínio do tempo são tão importante quanto o contrário.

Uma das transformadas disponíveis, a transformada discreta de Fourier (DFT – *Discrete Fourier Transform*) e o algoritmo para sua rápida computação, a transformada de rápida Fourier (FFT – *Fast Fourier Transform*), é a mais conhecida e a mais utilizada (Ifeachor e Jervis, 1995). Elas permitem a representação adequada no domínio da frequência para todos os dados (menos os que têm duração menor que $<1s$); as componentes de frequência da transformada de Fourier fornecem uma representação mais fiel do que outras séries exponenciais; as componentes individuais são sinusoidais e não são distorcidas durante a transmissão através de sistemas lineares; e a FFT pode ser calculada muito rapidamente. Além disso, a análise de Fourier existe desde 1822 com a publicação de Fourier e tem, portanto, encontrado um alto grau de similaridades, respeitabilidade e desenvolvimentos, assim como, um número muito grande de aplicações.

Existem outras transformadas, como a transformada de Laplace, Walsh e a de Hadamart e a transformada em z (Ifeacchor e Jervis, 1995); porém, além da FFT são as transformadas Wavelets que estão abrindo novos horizontes dentro da área de processamento de sinais e imagens.

Neste capítulo descreve-se os aspectos essenciais das transformadas de Fourier e a Wavelets.

4.1.1 Transformada de Fourier

A essência da transformada de Fourier de um sinal é decompor ou separar o sinal como uma soma de senóides de diferentes frequências.

A transformada de Fourier contínua foi a princípio uma ferramenta analítica muito usada em diversos campos, tais como: sistemas lineares, ótica, teoria da probabilidade, física quântica, e análise de sinal (Bracewell, 1965). O mesmo não se pode afirmar sobre as

transformadas de Fourier Discretas. Até mesmo com a velocidade computacional dos computadores modernos, as transformadas discretas de Fourier encontraram poucas aplicações devido à quantidade exorbitante de tempo de computação requerido (Brigham, 1974). Contudo, com o desenvolvimento da transformada rápida de Fourier (um algoritmo que calcula eficientemente a transformada discreta de Fourier), muitas facetas das análises científicas foram completamente revolucionadas.

A essência do cálculo da transformada rápida de Fourier é uma série de operações matemáticas conhecidas como transformada discreta de Fourier que é um conjunto m de variáveis no domínio da frequência a partir de um conjunto n de amostras no domínio do tempo. A Figura 4.1 ilustra um sinal $x(n)$ com N amostras em intervalos de T segundos.

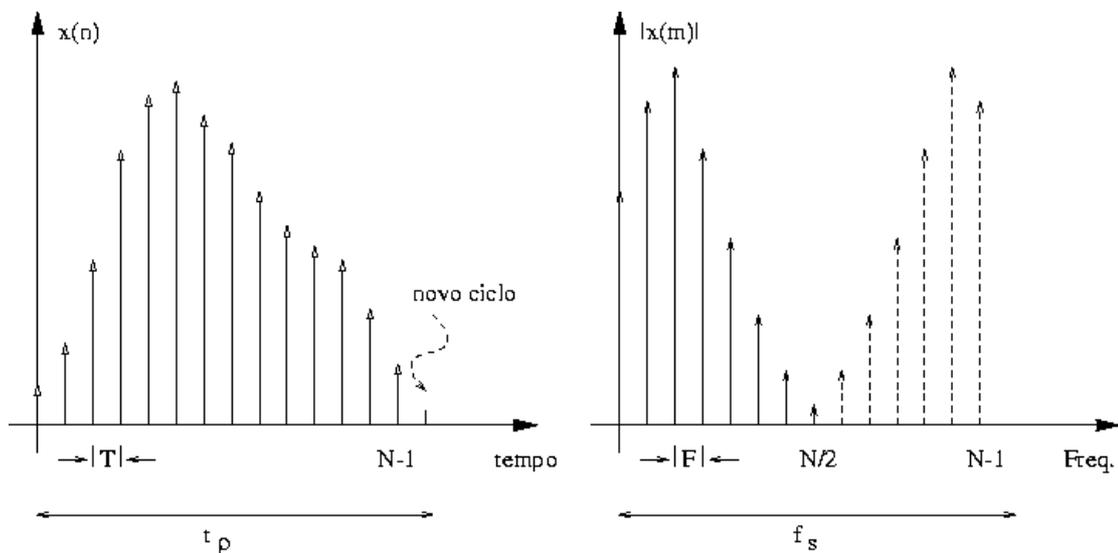


Figura 4.1 Amostragem em função do tempo e seu espectro (DFT)
Fonte: Modif. de Kuc (1992)

A DFT de $x(n)$ é definida pela soma finita:

$$X(k) = \sum_{n=0}^{N-1} x(n)W^{nk}, \quad \text{onde } W = e^{-i2\pi/N}. \quad (4.1)$$

A função $X(k)$ gera k variáveis no domínio da frequência com incremento $F = 1/t_s$.

Para $x(n)$ real com N amostras, um único espectro pode ser calculado para $N/2$ pontos da frequência. Na verdade, $X(k)$ é uma função periódica em k com N pontos em cada período, mas apenas $N/2$ são únicos (como pode ser observado nos pontilhados da Fig. 4.1).

Observando a definição da DFT, verifica-se que são necessárias cerca de N multiplicações e adições complexas para computar o espectro de cada k em particular e, se forem calculados $N/2$ componentes espectrais, o número de operações para o cálculo de todo o espectro é da ordem de N^2 . Como foi demonstrado por Cooley e Tukey (1965) pode-se calcular esta transformada com um número de processos computacionais da ordem de $N \log_2(N)$, o que poupa um grande esforço computacional. Este método é conhecido como Transformada Rápida de Fourier (FFT).

Os algoritmos de FFT funcionam melhor quando o número de pontos da amostra é uma potência inteira de 2, ou seja: $N = 2^j$, onde j é um inteiro positivo. Um programa que utiliza FFT com a finalidade de realizar análise espectral, apresenta certas particularidades na relação entre a FFT e a transformada contínua de Fourier. Deve-se considerar que o tratamento matemático considera o sinal como se ele fosse periódico, embora, na realidade, o sinal pode não ser periódico no sentido matemático estrito.

Um algoritmo para o cálculo da FFT deve levar em consideração alguns fatores básicos. Se considera-se $N=2^j$, para j inteiro positivo, amostras em um período, e se T é o incremento entre cada amostra, então o período é $t_\zeta = 2^j T$. O espectro obtido da FFT, também será periódico e conterá 2^j componentes espectrais. Entretanto, se a amostragem em função do tempo for real, pode ser demonstrado que metade dos componentes são coincidentes, logo apenas $N/2$ componentes espectrais complexos são significativos. Tais componentes são incrementados de $F = \frac{1}{t_\zeta}$ $k=0$ corresponde a componente DC, $k=1$ é a fundamental, $k=2$ é o segundo harmônico, etc.. Para se evitar a sobreposição espectral, a taxa de amostragem deve ser maior ou igual ao dobro da maior frequência do espectro, ou seja, se a maior frequência for f_k , o máximo intervalo entre as amostras deve satisfazer a equação:

$$T < \frac{1}{2f_k} \quad (4.2)$$

de acordo com o Teorema de Niquist (Kuc, 1982).

O uso da transformada de Fourier tem muitas aplicações, na realidade em qualquer campo de ciência física que utiliza sinais de sinusoidal na sua teoria, como engenharias,

físicas, matemática aplicada, e química, usam a teoria de Fourier e as transformadas. Como se pode observar seria quase impossível dar exemplos de todas as áreas onde a FFT está envolvida, assim as aplicações listadas a seguir estão relacionadas à engenharia e ao processamento de sinal: Comunicação, Sísmico, Sonar, Astronomia, Óptica, Acústica. Por exemplo, a pesquisa sísmica sempre foi uma usuária comum para a Transformada de Fourier Discreta (e a FFT). O uso original da FFT era distinguir entre eventos sísmicos naturais e explosões de testes nucleares. A FFT pode contar a diferença entre os dois porque os eventos sísmicos naturais têm uma resposta de frequência diferente (espectro) daquela dos eventos sísmicos causados por explosões nucleares (WWW_02, 2000).

4.1.2 Transformada Wavelets

As Wavelets são ondas pequenas (*ondeletes*, em francês) com determinadas propriedades que as tornam adequadas a servirem de base para decomposição de outras funções, assim como senos e cossenos servem de base para decomposições de Fourier.

Conforme cita Graps (1995), alguns pesquisadores acreditam que a utilização de *Wavelets* abre uma nova perspectiva na análise de dados. De 15 anos para cá, a Teoria das *Wavelets* tem despertado enorme interesse em todas as áreas.

As origens da teoria Wavelet remontam aos anos 30, quando, ainda sem corpo, podia ser discretamente identificada em trabalhos de Análise Funcional e outros ramos matemáticos. Sua emancipação ocorre nos anos 80 (Perier et al., -), fruto natural de seu uso e aplicação em prospecção mineral, análise e tratamento de imagens, entre outras. A Transformada Wavelet é uma ferramenta de processamento de sinais que tem um trunfo sobre as técnicas clássicas de Fourier: suas funções bases (wavelets) não pertencem a um espaço finito de soluções, isto é, existem teoricamente infinitas possibilidades de se projetar wavelets com propriedades especiais, voltadas para aplicações específicas. Pode-se projetar wavelets otimizadas para realizar análises especiais, onde as wavelets tenham características semelhantes aos sinais sob análise: uma espécie de Homeopatia Matemática -a cura pelos semelhantes, a análise pelo "self" (Dovicchi, 1999). Assim, as wavelets que são utilizadas para compressão de dados, podem revelar-se péssimas para aplicações de análises de sinais biológicos, ou síntese de música.

As wavelets podem ter caráter fractal, e terem padrões que se repetem em escalas diferentes. A análise de sinais com wavelets permite a extração de dados coerentes tanto no domínio da frequência quanto no do tempo (ou espaço, para imagens). A análise com wavelets pode ser vista como uma decomposição atômica, onde se buscam os componentes básicos dos sinais, os átomos. Uma vez descritos os "átomos" do sinal, mais fica fácil para se combinar e produzir novas moléculas. Por exemplo, numa partitura musical tem-se um arranjo de átomos (as notas) que possuem duração e frequência determinadas.

A análise de dados de acordo com escalas variáveis no domínio do tempo e da frequência é a idéia básica da utilização da teoria das *Wavelets*.

As *Wavelets* são funções matemáticas que ampliam intervalos de dados, separando-os em diferentes componentes de frequência, permitindo a análise de cada componente em sua escala correspondente. Uma função *Wavelet* adequada a um conjunto de dados permite uma representação esparsa desse conjunto. Isso torna as *Wavelets* uma excelente ferramenta de compressão de dados. Outros campos de aplicação das *Wavelets* (Daubechies, 1996; Graps, 1995) incluem astronomia, acústica, física nuclear, processamento de imagem e de som, música, fractais, turbulência, etc., o que tem despertado um grande interesse dos cientistas.

Existem vários tipos de *Wavelets*, dentre as quais a mais simples é a *Wavelet de Haar* (Figura 4.2):

$$\psi_{jk}(x) = C \cdot \psi(2^j x - k), \quad (4.3)$$

onde C é uma constante e ψ define uma base ortogonal em $L^2(\mathbf{R})$ ¹⁷, ou seja, cada elemento em $L^2(\mathbf{R})$ pode ser representado por uma combinação linear, que pode ser infinita, dessas bases.

Uma vez estabelecida uma base *Wavelet* $\psi(x)$ - chamada *Wavelet mãe* - pode-se estabelecer bases de translação e dilação da *Wavelet mãe*, tal que: $\left\{ \psi\left(\frac{x-b}{a}\right) \mid (a,b) \in \mathfrak{R}^+ \times \mathfrak{R} \right\}$,

¹⁷ $L^2(R)$, chamado de espaço de Hilbert, é um conjunto das sucessões de números complexos $x=(\lambda_k)$, tal que: $\lambda = \alpha + j\beta$ de somas quadráticas absolutas, tal que: $\sum_1^\infty |\lambda_k| < \infty$.

onde os valores de a e b devem ser selecionados convenientemente¹⁸, na definição da base, tal que: $a=2^j$ e $b = k2^j$, onde k e j são inteiros. A escolha de a e b proporcionará uma base esparsa e, além disso, possibilitará a análise com múltiplas resoluções no processamento de sinais. Assim, o grande mérito das *Wavelets* está no fato de que a análise no domínio do tempo é feita através de uma contração¹⁹, enquanto a análise no domínio da frequência se é feita por uma dilatação²⁰ dos espaços da função.

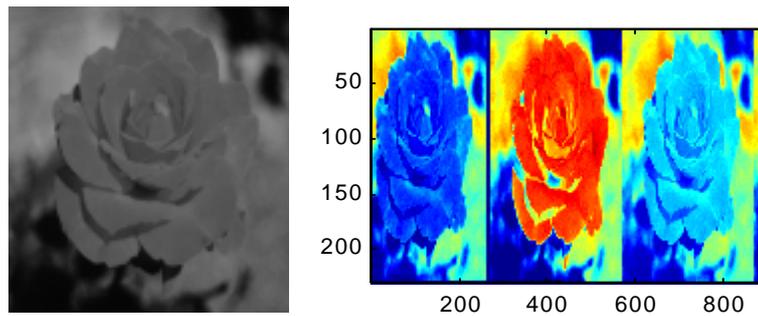


Figura 4.2: Transformada wavelet de Haar da figura original a esquerda.

Atualmente, os programas para a computação de transformadas *Wavelets* podem ser encontrados em C, FORTRAN e MATLAB.

A vantagem das *Wavelets* sobre os métodos tradicionais de Fourier é que a base das funções de Fourier é dependente da frequência, mas não do tempo, ou seja, pequenas alterações no domínio da frequência produzem alterações em todo o domínio do tempo. As *Wavelets* são dependentes de ambos os domínios, da frequência (via dilatação) e do tempo (via translação) (Dovicchi, 1999). Por muitas décadas, os cientistas procuraram funções mais apropriadas do que senos e cossenos para análise de sinais. As bases das funções de Fourier são impróprias para o tratamento local de dados, pois são séries infinitas e não se adaptam à análise de dados descontínuos. As *Wavelets* não só se prestam à aproximação de funções finitas, como também servem para análise de dados descontínuos.

¹⁸ Note que se $(a, b) \in \mathcal{R}^+ \times \mathcal{R}$, a é um valor positivo, enquanto b é um real qualquer, e o espaço é o produto cartesiano de a e b .

¹⁹ Versão de alta frequência da *Wavelet mãe*.

²⁰ Versão de baixa frequência da *Wavelet mãe*.

Quadro 4.1 – Comparação entre a Transformada de Fourier e a de Wavelet

Transformada de Fourier x Transformada Wavelet
<ul style="list-style-type: none"> ❑ Ambas são operadores lineares ❑ Ambas as transformadas são rotações, no espaço de uma função, de um domínio para outro. ❑ A transformada de Fourier usa senos e cossenos como base. ❑ A Transformada Wavelet usa bases mais complexas chamadas Wavelet Mãe, Wavelets ou Wavelets analíticas. ❑ Uma função <i>Wavelet</i> isolada é espacialmente localizada no domínio do tempo e da frequência, enquanto as senóides e cossenóides de Fourier não o são. Essa característica confere as funções <i>Wavelets</i>, a propriedade de tornarem-se esparsas quando transformadas de um domínio para outro, possibilitando, desta forma, sua aplicação na remoção de ruídos de uma série no domínio do tempo (Perrier et al.,-).

4.2 Filtros

O filtro digital é um dos grandes campos de aplicação de Processamento Digital de Sinal.

Um filtro é essencialmente um sistema ou uma rede que seletivamente muda a forma da onda, amplitude-frequência e/ou fase-frequência, características de um sinal, de uma maneira desejável (Ifeachor e Jervi, 1995). Os objetivos dos filtros são: melhorar a qualidade do sinal (por exemplo, remover ou reduzir ruídos), extrair informações dos sinais ou separar dois ou mais sinais previamente combinados para fazer, por exemplo, o uso eficiente de um canal de comunicação disponível.

Um filtro digital é um algoritmo matemático implementado em hardware ou software que opera sobre um sinal digital para produzir um sinal de saída desejado. Os filtros digitais freqüentemente operam sobre sinais analógicos digitalizados ou simplesmente sobre seqüências de números, representando alguma variável, armazenadas na memória do computador.

A Figura 4.3 mostra um diagrama simplificado de um filtro digital, com sinal de entrada analógico $x(t)$ e sinal de saída $y(t)$. O sinal analógico é amostrado periodicamente pelo ADC (*Analog to Digital Converter*) e convertido numa série de amostras digitais, $x(n)$, $n = 1, 2, \dots$. O processador digital implementa a operação de filtragem, mapeando a seqüência de entrada, $x(n)$, em uma seqüência de saída, $y(n)$, de acordo com o algoritmo computacional para o filtro. O DAC (*Digital to Analog Converter*) converte o sinal de saída filtrado em

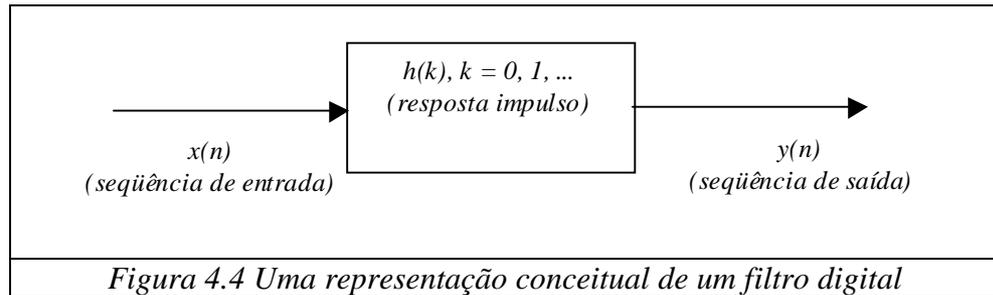
valores analógicos que são, então, filtrados de forma analógica para suavizar e remover componentes de alta frequência indesejáveis (Ifeachor e Jervis, 1995).



Figura 4.3 Diagrama simplificado de um filtro digital
 Fonte: Ifeachor e Jervis, 1995

Os filtros digitais têm um papel muito importante em DSP. Comparados com os filtros analógicos eles são preferidos em uma série de aplicações como: compressão de dados, processamento de sinais biomédicos, processamento de voz, processamento de imagens, transmissão de dados, áudio digital e o cancelamento do eco no telefone, devido a uma ou mais das seguintes vantagens (Ifeachor e Jervis, 1995):

- Os filtros digitais têm algumas características que não são possíveis com filtros analógicos, tal como, uma resposta de fase linear verdadeira.
- Diferente dos filtros analógicos, o desempenho dos filtros digitais não varia com mudanças do meio, por exemplo, variações térmicas. Isto elimina a necessidade da calibragem periódica.
- A resposta de frequência do filtro digital pode ser automaticamente ajustada se ele for implementado usando um processador programável, e é por isto que eles são amplamente usados nos filtros adaptativos.
- Diversos sinais ou canais de entrada podem ser filtrados por um único filtro sem a necessidade de replicar o hardware.
- Os filtros digitais podem ser usados em frequências muito baixas, encontradas, por exemplo, em muitas aplicações da biomédica, onde o uso de filtros analógicos é impraticável. Os filtros digitais também podem ser elaborados para trabalhar sobre um intervalo grande de frequências por uma simples mudança nas frequências amostradas.



4.2.1 Exemplos de Filtros Digitais Simples

Os exemplos seguintes ilustram as características essenciais de alguns filtros digitais (WWW_03, 1999).

(Nos exemplos abaixo considere x_n ($n= 0, 1, 2, \dots, N$) um sinal digital.)

1) Filtro de ganho simples:

$$y_n = Kx_n, \quad n = 0, 1, 2, \dots, N \quad (4.4)$$

onde K é uma constante.

Este filtro aplica um fator de ganho K para cada valor de entrada. $K > 1$ faz do filtro um amplificador, enquanto $0 < K < 1$ faz do filtro um atenuador. Se K é negativo tem-se um amplificador ou atenuador invertido. Se $K=1$, tem-se o próprio sinal.

2) Filtro de atraso puro:

$$y_n = x_{n-1}, \quad n = 0, 1, 2, \dots, N \quad (4.5)$$

O valor da saída no tempo n assume o valor da entrada no tempo $n-1$, isto é, o sinal é atrasado.

Neste caso, como x_{-1} não está definido, toma-se qualquer valor, geralmente zero. Assim tem-se: $y_0 = x_{-1} = 0$; $y_1 = x_0$; $y_2 = x_1$;

3) Filtro da diferença de dois termos:

$$y_n = x_n - x_{n-1}, \quad n = 0, 1, 2, \dots, N \quad (4.6)$$

O valor da saída no tempo n é igual a diferença entre a entrada corrente x_n e a entrada anterior x_{n-1} .

4) **Filtro da Média de dois termos:**

$$y_n = \frac{(x_n + x_{n-1})}{2} \quad n = 0, 1, 2, \dots, N \quad (4.7)$$

A saída é a média aritmética da entrada corrente com a entrada anterior. Este é um tipo simples de filtro de passa baixa que tende a suavizar variações de frequência altas em um sinal.

5) **Filtro da Média de três termos:**

$$y_n = \frac{(x_n + x_{n-1} + x_{n-2})}{3}, \quad n = 0, 1, 2, \dots, N \quad (4.8)$$

Este filtro é similar ao anterior, com a média sendo tomada da entrada corrente e as duas entradas anteriores.

6) **Filtro de Diferença Central:**

$$y_n = \frac{(x_n - x_{n-2})}{2}, \quad n = 0, 1, 2, \dots, N \quad (4.9)$$

Este é semelhante em efeito ao exemplo 3. A saída é igual a metade da diferença da entrada corrente e a segunda entrada anterior.

A ordem de um filtro digital é o número de entradas anteriores (armazenadas na memória) usadas para calcular a saída corrente. Desta forma, o exemplo (1) é de ordem zero, os exemplos, (2), (3) e (4) são de primeira ordem e os exemplos (4) e (6) são de segunda ordem.

Todos os filtros digitais dos exemplos dados anteriormente podem ser escritos na seguinte forma geral:

$$k\text{-ésima ordem: } y_n = a_0 x_n + a_1 x_{n-1} + a_2 x_{n-2} + \dots + a_k x_{n-k} \quad (k \leq N) \quad (4.10)$$

As constantes a_0, a_1, a_2, \dots que aparecem nestas expressões são chamadas de coeficientes dos filtros. Os valores destes coeficientes determinam as características de um filtro particular. A Tabela 4.1 mostra os valores dos coeficientes de cada um dos filtros dados nos exemplos acima.

Tabela 4.1 Coeficientes dos filtros dados nos exemplos anteriores

Exemplo	Ordem	a_0	a_1	a_2
1	0	K	-	-
2	1	0	1	-
3	1	1	-1	-
4	1	$\frac{1}{2}$	$\frac{1}{2}$	-
5	2	$\frac{1}{3}$	$\frac{1}{3}$	$\frac{1}{3}$
6	2	$\frac{1}{2}$	0	$-\frac{1}{2}$

4.2.2 Tipos de filtros Digitais: Recursivos e Não Recursivos

Em todos os exemplos de filtros visto neste capítulo, a saída corrente y_n depende somente dos valores das entradas correntes e anteriores (x_n, x_{n-1}, \dots). Este tipo de filtro é chamado de **filtro não recursivo**.

Um filtro **recursivo** além de usar entradas correntes e anteriores utiliza também valores de saídas prévias.

Exemplo de Filtro Recursivo: Um exemplo simples de um filtro digital recursivo é dado por:

$$y_n = x_n + y_{n-1} \quad (4.11)$$

Esse filtro determina a saída corrente (y_n) pela adição da entrada corrente com a saída anterior. (Neste caso, também não se tem y_{-1} , então usualmente, atribui-se zero.)

Os efeitos destes filtros podem ser considerados com mais detalhes. Por exemplo, para calcular y_{10} é necessária apenas uma adição:

$$y_{10} = x_{10} + y_9. \quad (4.12)$$

Para encontrar o mesmo efeito com um filtro não recursivo (sem usar as saídas prévias armazenadas na memória) pode-se usar a equação:

$$y_{10} = x_{10} + x_9 + x_8 + x_7 + x_6 + \dots + x_0. \quad (4.13)$$

Nesse caso, além de serem necessárias 10 somas, é preciso armazenar 10 valores na memória.

Esse exemplo demonstra uma característica importante e útil dos filtros recursivos: a economia no número de operações e na quantidade de memória para o armazenamento.

Obs: Algumas pessoas preferem uma terminologia alternativa para nomear os filtros, no qual os filtros digitais não-recursivos são conhecidos, como: filtro FIR (ou *Finite Impulse Response*) e os filtros digitais recursivos como: filtro IIR (ou *Infinite Impulse Filter*).

Esses termos se referem às diferenças da "resposta impulso" ²¹ dos dois tipos de filtros. Um filtro FIR é aquele cujas respostas impulsos é de duração finita. Um filtro IIR é aquele cujas respostas impulsos, teoricamente, continuam sempre devido aos termos da recursividade. O termo IIR não é muito preciso, pois a resposta impulso atual de quase todos os filtros IIR reduzem virtualmente para zero em um tempo finito. Contudo, estes dois termos são amplamente usados.

4.2.3 Ordem de um filtro digital

A ordem de um filtro digital foi definida anteriormente como o número de entradas prévias que devem ser armazenadas a fim de gerar uma dada saída. Esta definição é apropriada para filtros não-recursivos, que usa somente as entradas prévias e a corrente para calcular a saída corrente. No caso de filtros recursivos, a definição pode ser estendida como:

A ordem de um filtro recursivo é o maior número de entradas ou saídas prévias requeridas para computar a saída corrente.

Esta definição pode ser considerada genérica: aplica-se a filtros recursivos e não-recursivos.

4.2.4 Coeficientes dos filtros digitais

Da discussão acima, pode-se notar que um filtro recursivo é basicamente como um filtro não-recursivo, com a adição de termos extras envolvendo saídas prévias. Um filtro recursivo de segunda ordem pode ser escrito na forma genérica:

$$y_n = \frac{(a_0 x_n + a_1 x_{n-1} + a_2 x_{n-2} - b_1 y_{n-1} - b_2 y_{n-2})}{b_0} \quad (4.14)$$

A razão para expressar o filtro deste modo é permitir reescrevê-lo na seguinte forma:

²¹ A resposta impulso de um filtro digital é a seqüência de saída do filtro quando um impulso unitário é aplicado em sua entrada.

$$b_0 y_n + b_1 y_{n-1} + b_2 y_{n-2} = a_0 x_n + a_1 x_{n-1} + a_2 x_{n-2} \quad (4.15)$$

Esta forma alternativa é chamada de forma simétrica do filtro. Note que os coeficientes das entradas são denotados pelos a's e os coeficientes das saídas por b's.

Então, para um filtro digital recursivo têm-se dois conjuntos de coeficientes: os coeficientes das entradas e os coeficientes das saídas.

Genericamente, costuma-se na literatura (Ifeachor e Jervis, 1995) usar a seguinte representação:

FIR de ordem k com coeficientes a_0, a_1, \dots, a_k :

$$\frac{y_n}{x_n} = a_0 + a_1 z^{-1} + a_2 z^{-2} \dots + a_k z^{-k} \quad (4.16)$$

IIR de ordem k com coeficientes a_0, a_1, \dots, a_k e b_0, b_1, \dots, b_k :

$$\frac{y_n}{x_n} = \frac{a_0 + a_1 z^{-1} + a_2 z^{-2} \dots + a_k z^{-k}}{b_0 + b_1 z^{-1} + b_2 z^{-2} \dots + b_k z^{-k}} \quad (4.17)$$

onde $\frac{y_n}{x_n}$ é representado por $H(z)$ e é chamado de *função de transferência*.

Na elaboração do projeto de um filtro um dos principais problemas encontrados é a determinação dos coeficientes. Existem diversos métodos para a determinação dos coeficientes que dependem do filtro ser do tipo IIR ou FIR.

Os filtros digitais do tipo FIR não têm contrapartida no mundo analógico, na medida em que implementam diretamente um sistema discreto a partir da sua resposta impulsional $a(n)$, finita. Esses filtros podem ser realizados com fase exatamente linear, correspondente a um atraso fixo da saída relativamente à entrada, permitindo que no seu projeto a atenção do projetista se concentre na resposta em amplitude. Além disso, são garantidamente estáveis quando implementados não recursivamente.

Os filtros digitais do tipo FIR são também muito usados na realização de sistemas adaptativos.

²² z^{-k} é chamado operador atraso (*delay*) onde $z^{-k} x_n = x_{n-k}$ e analogamente $z^{-k} y_n = y_{n-k}$

Os três métodos básicos usados na determinação dos coeficientes são (Ifeachor e Jervis, 1995; Restivo, 1998):

- método da janela
- método da amostragem da função de transferência
- projeto ótimo (algoritmo de Remez).

Os filtros digitais do tipo IIR, por outro lado, podem ser facilmente relacionados com filtros analógicos e são normalmente menos exigentes em termos do número de operações necessárias para realizar uma determinada resposta em frequência.

Os cálculos dos coeficientes dos filtros IIR são baseados em transformadas. Estes filtros são normalmente projetados tomando como ponto de partida um filtro analógico, que é transformado num filtro digital por um dos seguintes métodos principais (Ifeachor e Jervis, 1995; Restivo, 1998):

- **método da invariância da resposta impulsional**
- **método da transformação bilinear**

O método usado, em ambos os tipos de filtros, depende da aplicação particular. A escolha é influenciada por diversos fatores, onde os mais importantes são os requerimentos críticos nas especificações. Em geral, a escolha crucial está entre os filtros FIR e IIR. Na maioria dos casos, se as propriedades dos filtros FIR são vitais então um bom candidato é o método ótimo, por outro lado, se as propriedades dos filtros IIR são desejáveis, então o método bilinear na maioria dos casos é suficiente.

4.2.5 Vantagens e desvantagens dos filtros FIR e IIR

A escolha entre os filtros FIR e IIR depende muito das vantagens que eles oferecem:

- Os filtros FIR podem ter uma resposta de fase linear exata, ou seja, o filtro não introduz nenhuma distorção na fase do sinal. Este é um requerimento importante em muitas aplicações, por exemplo, transmissão de dados, biomedicina, áudio digital e processamento de imagens. A resposta de fase dos filtros IIR é não linear.
- Os filtros FIR que não são recursivos são sempre estáveis. A estabilidade dos filtros IIR não pode ser garantida sempre.

- Os filtros FIR requerem mais coeficientes para remover os picos que os filtros IIR. Então, para uma determinada especificação de resposta de amplitude, mais tempo de processamento e armazenagem serão requeridos para a implementação. Contudo, pode prontamente tomar vantagem da velocidade computacional das FFT para melhorar significativamente a eficiência das implementações dos FIR.
- Os filtros analógicos podem ser prontamente transformados em filtro digitais IIR através de especificações semelhantes. Isto não é possível com os filtros FIR, pois eles não têm nenhuma contraparte analógica. Contudo, com FIR é mais fácil sintetizar filtros de respostas de frequências arbitrárias.

O Quadro 4.3 resume as considerações acima sobre quando usar o filtro IIR e FIR.

Quadro 4.2 – Comparação entre os Filtros IIR e os Filtros FIR

Filtros IIR	Quando os únicos requerimentos importantes são remover picos e alto processamento.
Filtros FIR	Se o número de coeficientes não é muito grande, e em particular, se nenhuma ou uma pequena distorção na fase é desejada.

4.2.6 Filtros Adaptativos

Um filtro adaptativo é essencialmente um filtro digital com a característica de ser auto-ajustável (Ifeachor e Jervis, 1995). Os algoritmos (recursivos) começam de algum conjunto predeterminado de condições iniciais, representando tudo o que se conhece sobre o meio. Como consequência direta da aplicação deste algoritmo os parâmetros (coeficientes) do filtro são adaptados de uma iteração para outra, e com isto tornam-se dependente dos dados (Haykin, 1996).

Os filtros adaptativos são o tópico central nesta área de DSP conhecida como processamento adaptativo de sinal.

A contaminação de um sinal de interesse por outro não desejado é um problema geralmente encontrado em muitas aplicações. Quando o sinal e o ruído ocupam bandas fixas e separadas, os filtros lineares tradicionais com coeficientes fixos são normalmente usados para extrair o sinal. Contudo, existem muitos casos onde é necessário que as características dos

filtros seja variáveis, adaptadas inteligentemente para se adequar às mudanças do sinal. Em tais casos, os coeficientes dos filtros devem variar e não podem ser especificados com antecedência. Isto ocorre, por exemplo, onde existe uma sobreposição espectral entre o sinal (ver Figura 4.3) e o ruído ou se a banda ocupada pelo ruído é desconhecida ou varia com o tempo.

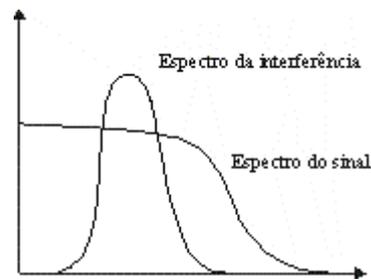


Figura 4.5: Ilustração de sobreposição espectral entre o sinal e a interferência

Fonte: Ifachor e Jervis, 1995

Uma aplicação típica onde os coeficientes fixos são inapropriados é o caso dos sinais de um eletrooculograma (EOG), onde os artefatos ou a contaminação produzidos pelo movimento dos olhos ou pelas piscadas são muito maiores que a atividade elétrica genuína do cérebro e formam a mesma banda de frequência com os sinais de interesse clínico. Neste caso, não é possível usar filtros lineares convencionais para remover os artefatos enquanto preservam os sinais de interesse clínico.

Num filtro adaptativo sua resposta de frequência é ajustável ou modificada automaticamente para melhorar o seu desempenho de acordo com algum critério. Isso permite que o filtro se adapte às mudanças das características do sinal de entrada. Devido ao seu desempenho auto-ajustável e sua flexibilidade construída, os filtro adaptativos têm encontrado utilidade em diversas aplicações (Quadro 4.2).

Em resumo, usam-se filtros adaptativos (Ifachor e Jervis, 1995):

- quando é necessário que as características do filtro sejam variáveis, adaptadas a condições variáveis,
- quando existe uma sobreposição espectral entre o sinal e o ruído, ou
- se a banda ocupada pelo ruído é desconhecida ou varia com o tempo.

Quadro 4.3 – Aplicações dos Filtros Adaptativos

Classe de filtro adaptativo	Aplicação
I. Identificação	Sistemas de Identificação Modelagem das camadas da terra
II Modelagem Inversa	Deconvolução Preditiva Equalização Cega Equalização Adaptativa
III. Predição	Codificação Preditiva Linear Análise Espectral Autoregressiva Detecção de sinal
IV. Cancelamento de Interferência	Cancelamento de Ruído Adaptativo Cancelamento de Eco Filtragem Espacial

Fonte: Haykin, 1996

O uso de filtros convencionais nos casos acima levaria a uma distorção inaceitável do sinal desejado.

Na maioria dos sistemas adaptativos, o filtro é concebido usando uma estrutura de resposta de impulso finito (FIR) ou transversal. Outra forma, algumas vezes usada, é a estrutura de resposta de impulso infinito (IIR) ou a de *lattice*. Porém, a estrutura FIR é a mais amplamente usada devido a sua simplicidade e a garantia de estabilidade. Para o filtro de ordem N esboçado na Figura 4.6, a saída é dada por:

$$y_k = \sum_{i=0}^{N-1} w_k(i) x_{k-i} \quad (4.18)$$

onde $w_k(i)$, $i = 0, 1, \dots, N-1$, são os coeficientes ajustáveis do filtro (parâmetros ou pesos), e $x_k(i)$ e y_k são as entradas e as saídas do filtro respectivamente.

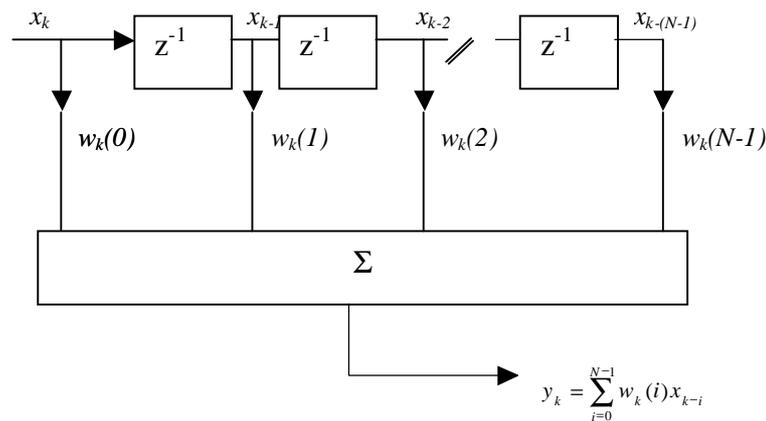


Figura 4.6 Estrutura de um filtro FIR
 Fonte: Ifeachor e Jervis (1995)

Os filtros adaptativos são divididos em dois grupos: lineares e não lineares. Um filtro adaptativo é dito ser linear se a estimativa da saída do filtro é calculada adaptativamente como uma combinação linear do conjunto disponível aplicado na entrada do filtro. Caso contrário é dito ser não linear.

Os FA lineares, por sua vez, são também divididos em dois grupos de acordo com a abordagem utilizada (Ifeachor e Jervis, 1995):

- Abordagem do gradiente estocástico onde se têm os algoritmos de Wiener e o LMS (*Least Mean Square*)
- Abordagem da Estimação do Mínimo Quadrado (*Least-Square*) onde se têm o algoritmo RLS (*Recursive Least Square*) e suas variações.

Os FA não lineares podem ser baseados na série de Volterra, que é uma generalização da série de Taylor, ou nas redes neurais artificiais (RNA), que consistem da interconexão de um grande número de unidades de processamento não lineares, chamados neurônios. As RNA além de serem algoritmos adaptativos têm a capacidade de aprendizagem (Haykin, 1996).

Maiores detalhes sobre os filtros adaptativos lineares e não lineares podem ser encontrados em literatura específica, como em Haykin (1996).

Dada esta variedade de FA disponíveis, como escolher um deles para uma aplicação de interesse? A escolha poderá ser feita levando em consideração o custo-benefício. Com este objetivo em mente, pode-se identificar três importantes questões que requerem atenção: custo computacional, desempenho e robustez. O uso da simulação fornece um bom primeiro passo

na tarefa de uma investigação detalhada destas questões. Pode-se começar usando o algoritmo LMS como uma ferramenta de filtragem adaptativa para o problema em estudo. O algoritmo LMS é relativamente simples de implementar e é eficiente o suficiente para avaliar os benefícios práticos que podem resultar da sua aplicação ao problema a ser resolvido. Além disto, fornece uma estrutura prática de referência para a avaliação de qualquer melhoramento que pode ser obtido através do uso de algoritmos adaptativos de filtragem mais sofisticados. Finalmente, o estudo deve incluir teste com dados reais.

As aplicações práticas de filtros adaptativos são muito diversas, cada aplicação tendo suas peculiaridades. A solução para uma aplicação pode não ser desejável para outra. Contudo, para ter sucesso tem-se que desenvolver um entendimento do meio no qual o filtro tem que operar e desse modo relatar as realidades da aplicação de interesse.

4.3 Conclusão

Com relação às transformadas, serão as de wavelets que guiarão as pesquisa nesta área. A Teoria Wavelet foi estruturada na década de 80, sendo, portanto um assunto novo, com muito campo ainda pela frente. Essa frase não é nova, mas continua sendo verdade, pois o desenvolvimento das ciências computacionais aponta para uma tendência em que o processamento de sinais (imagens, sons, padrões biológicos, sinais volumétricos, etc.) torna-se cada vez mais presente, indispensável. As técnicas indicadas para processar sinais complexos de uma forma adaptativa, "customizadas" para aplicações específicas e com alto poder de processamento, velocidade e eficiência são minas de ouro para se embutir tecnologia e inteligência artificial, esboçando um futuro onde "as máquinas" se enriquecerão em termos humanos, e poderão demonstrar comportamentos mais próximos do humano, com a vantagem de se estar eliminando fatores humanos indesejáveis. Isso tudo, segundo Faria (1997), pode soar como um futuro mórbido e artificial, mas sabe-se que a humanidade sempre manterá seu caráter crítico e revolucionário e que as chances de que essa evolução seja influenciada por novos movimentos sociais e crenças que modifiquem esta ascendência, são bastante consideráveis.

Quanto aos filtros, as pesquisas se voltam para os filtros adaptativos, principalmente os não lineares. Novos filtros serão desenvolvidos. E a tecnologia existente será

disponibilizada em produtos comerciais, revolucionando cada vez mais o mundo da comunicação (interplanetária e extraplanetária).

A área da biomédica será uma das grandes beneficiadas com o aperfeiçoamento e desenvolvimento de tecnologias de filtros e transformadas, no próximo século. Com auxílio dessa tecnologia, além da captura de sinais biológicos com maior eficiência e auxílio no diagnóstico, será possível montar uma base dados médica (com imagens, seqüências de vídeos de procedimentos médicos, ...) que poderá ser acessada com rapidez e eficiência via internet, telenet (Madisetti, 2000). A compressão de dados por wavelets contribuirá muita para a elaboração dessa base de dados.

5

Modelo Proposto: O Sistema Mapa FAN

5.1 Introdução

O tratamento com padrões que possuem uma quantidade muito grande de características é objeto de estudo e preocupação para muitos pesquisadores há várias décadas (Bellman, 1961, Duda e Hart, 1973). Porém, nas duas últimas décadas a busca, por métodos mais sofisticados e eficientes, tornou-se mais intensa, pois se tornou necessário explorar as informações contidas em dados de alta dimensão, como as imagens digitais e os sinais digitais (Schowengerdt, 1997, Souza, 1999).

Os estudos são focados na busca por representações em espaços de baixa dimensão, ou seja, extração de características que minimizam a quantidade de características, mas que mantenham as informações relevantes. O grande desafio é o equilíbrio entre a quantidade de características e a quantidade de informações. Um dos métodos mais usados é a Análise de Componentes Principais (Johnson e Wichern, 1998).

Na maioria dos casos, um estudo detalhado dos padrões é requerido para buscar formas de minimizar esse problema. Devido ao problema da multidimensionalidade dos padrões (Carreira-Perpiñán, 1997), muitos pesquisadores, buscam métodos para extrair as características relevantes antes de verificar a possibilidade de desenvolver métodos de classificação que trabalhem com os padrões em seu espaço original. Neste trabalho, o método proposto utiliza os dados no espaço de alta dimensão. Preocupando-se também com a forma de representar os dados (seção 5.3), tendo em vista o problema e o método utilizado para a classificação.

Um exemplo de representação em alta dimensão é os sinais de EEG. No estagiamento automático proposto (Capítulo 6) é usado o canal C3 do EEG. Nesse canal a captura dos dados é feita a uma taxa de 200 Hz, ou seja, em uma amostra (ou época²³) de 30 segundos são utilizados 6000 pontos (Figura 5.1). Em reconhecimento de padrões uma amostra é chamada de padrão. Nesse caso, tem-se um padrão com dimensão de 6000, ou 6000 características. Isso caracteriza um problema de alta dimensão. Analisando os padrões (amostras), vê-se que o que caracteriza o padrão é o contexto, neste caso, frequência, amplitude e periodicidade. Cada uma dessas amostras deve ser classificada.

O objetivo deste capítulo é apresentar um novo método de pré-processamento (ordenação) e novo método de classificação (Mapa FAN) desenvolvido especificamente para trabalhar com esses tipos de padrões provindos de sinais digitais. Os métodos, a princípio, poderão ser aplicados para outros problemas de processamento de sinais por amostras, com as devidas adaptações.

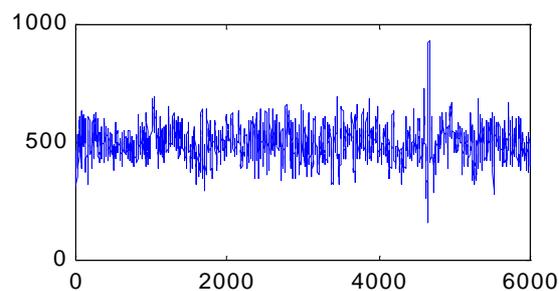


Figura 5.1 Amostra (30 s) do sinal do EEG do canal C3

O desenvolvimento do pré-processamento – ordenação – foi baseado na teoria da Informação (Seção 5.3). E a elaboração do modelo de classificação está relacionada a aspectos da inteligência artificial, devido sua inspiração estar vinculada a aspectos de redes neurais artificiais, bem como aos sistemas difusos, mais especificamente na rede híbrida FAN (seção 5.4).

A seção seguinte apresenta a arquitetura do sistema Mapa FAN que é composto de três módulos: pré-processamento (o que inclui a ordenação), classificação (Mapa FAN) e o pós-processamento. Essa arquitetura poderá ser utilizada para a classificação de sinais digitais por amostras.

²³ Os especialistas do sono chamam uma amostra de época.

5.2 Arquitetura

O sistema Mapa FAN foi desenvolvido com o objetivo de classificar sinais digitais de alta dimensão, como o reconhecimento de voz e classificação de sinais biológicos (como os sinais de EEG ou ECG). Sinais que são classificados utilizando trechos do sinal (amostras), como mostrado na Figura 5.2. A dimensão das amostras depende da frequência que o sinal é capturado.



Figura 5.2: Trechos do sinal (amostras)

Como o objeto de estudo é o sinal digital, geralmente, necessita-se realizar um pré-processamento como foi visto no Capítulo 3. Muitos pesquisadores utilizam os filtros digitais e as transformadas (Hadjiyannkis, 1997, Oropesa et al., 1999). Neste trabalho elaborou-se uma forma alternativa de pré-processamento baseada na ordenação dos sinais (seção 5.3) como um passo anterior à extração de características. Para o problema específico, da classificação das fases do sono, a extração de características é descrita na seção 6.3. Para a classificação desenvolveu-se um método baseado no sistema híbrido FAN (seção 5.4). Após a classificação, o sistema pode conter um módulo de pós-processamento baseado em regras (que depende da aplicação).

O sistema é composto então, de três módulos distintos: o pré-processamento, o classificador e o pós-processamento. A Figura 5.1 mostra a arquitetura do sistema Mapa FAN.

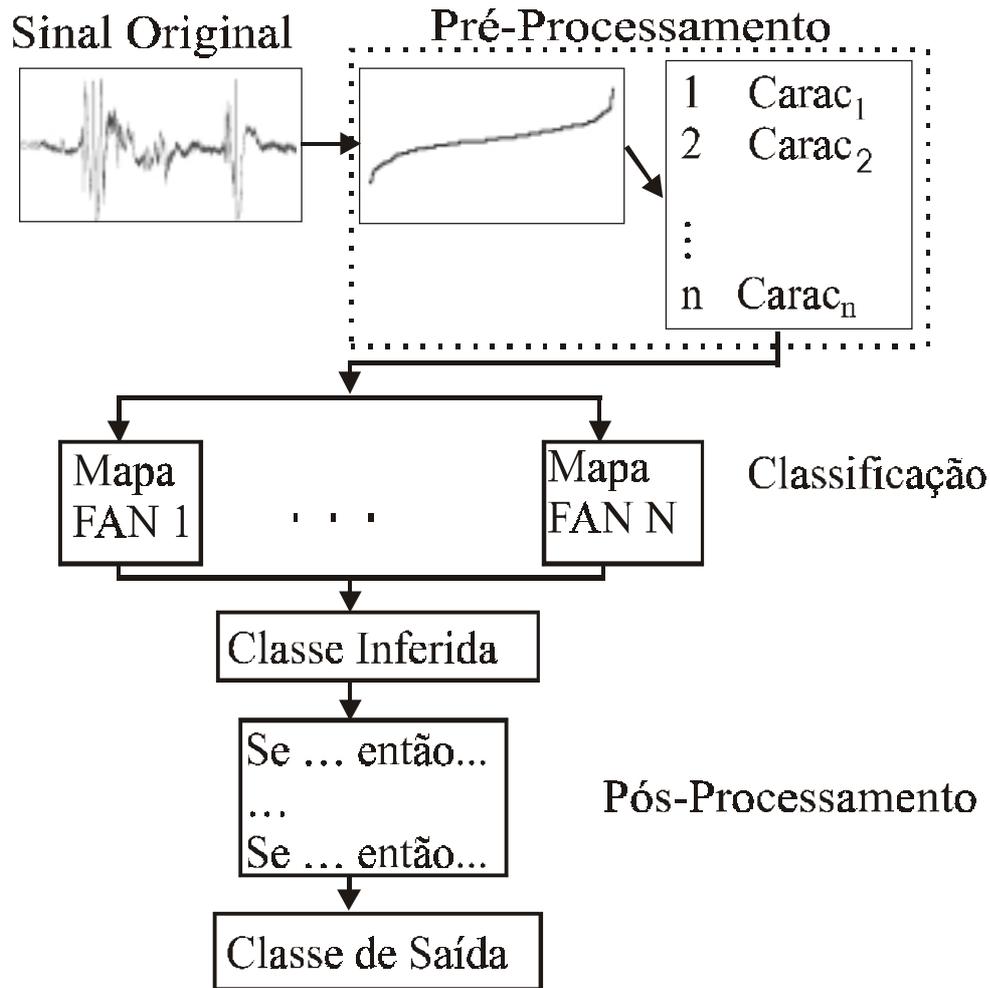


Figura 5.3 Arquitetura da Sistema Mapa FAN

5.3 Pré-Processamento: Ordenação

O pré-processamento dos dados representa um papel importante em todo sistema de classificação, sendo esse em *hardware* ou *software* (análogo ou digital). Como visto nos capítulos anteriores várias são as formas (técnicas) de realizar um processamento nos dados. Contudo, neste trabalho, optou-se pelo desenvolvimento de uma forma específica de pré-processamento que estivesse coeso com o modelo de classificação proposto.

Esta seção descreve, então, uma forma alternativa de pré-processamento de sinais digitais através da ordenação das amplitudes dos sinais. O método foi baseado na Teoria da Informação (TI). A ordenação do sinal fornece a forma, que segundo a TI, auxilia no processo de reconhecimento.

5.3.1 Teoria da Informação

A Teoria da Informação (TI) foi criada para auxiliar a solução de certos problemas de otimização do custo da transmissão de sinais (Shannon & Weaver, 1975). Hoje, por ser uma teoria atomística (Moles, 1969) (isto é, ela expõe seus conceitos básicos, demonstra seus teoremas fundamentais, pretendendo com isto dar conta da realidade ou pelo menos parte dela), está sendo usada em outras áreas como psicolinguística, estética, economia, desenho industrial, psicologia, biologia, pedagogia, entre outras.

Segundo a TI, quanto maior a desordem (a incerteza) maior a quantidade de informação. Por outro lado, a própria percepção, segundo a teoria gestáltica, só é possível na medida da emergência de uma forma que, vista à luz dos conceitos da TI, é forma porque contém menos variedade e, portanto, menos informação do que o estado caótico (desordenado).

A forma desempenha um papel importante na percepção, no reconhecimento dos objetos, e conseqüentemente, na memorização e no aprendizado (Epstein, 1988). Por outro lado, a forma equivale a uma diminuição da informação contida no estado desordenado.

Dentro da TI, a forma está diretamente relacionada com a redundância nos dados. Por exemplo, uma tela de TV, quando está sintonizada num canal fora do ar, aparece uma chuva de pontos (totalmente desordenados). Neste caso, tem-se a quantidade máxima de informação que o canal pode transmitir²⁴. A quantidade de informação é a medida da complexidade (então quanto mais complexo um sinal mais informação ele possui). Porém, para se ter uma imagem nítida na tela precisa-se da forma. Então, nota-se que a informação difere essencialmente da significação. Para ter significado necessita-se da redundância, da forma.

No caso dos sinais do eletroencefalograma, os dados são muito complexos, a quantidade de informação que eles transmitem é muito grande. Por isto, para entendê-los melhor, necessita-se da forma.

Uma maneira encontrada para obter-se esta forma foi através da ordenação das amplitudes das ondas (Figura 5.2).

²⁴ Por exemplo, se a emissora de TV tem a capacidade de transmitir 30 imagens por segundos, se cada imagem contém 525 linhas, e se cada linha permite uma resolução correspondente de 630 bits de informação, a capacidade de informação é de $30 \times 525 \times 630 = 9922500$ bits/seg.

5.3.2 Ordenação

Uma forma encontrada para auxiliar o entendimento de sinais complexos foi transformar o sinal original no sinal ordenado (ordenação das amplitudes) (Raittz et al., 1999).

O sinal é dividido em amostras (o tamanho da amostra depende dos dados e do problema) e, então cada amostra é ordenada. A ordenação do sinal de cada uma dessas amostras não obedece a nenhum outro critério a não ser a ordenação em ordem crescente segundo as amplitudes do sinal.

Seja $\mathbf{A} = (a_1, a_2, \dots, a_n)$ o conjunto de amplitudes de uma amostra do sinal. A ordenação dispõe os elementos de \mathbf{A} em ordem crescente, ou seja, é uma permutação dos elementos de \mathbf{A} ($Perm(\mathbf{A})$), tal que, para quaisquer a_i e a_{i+1} em \mathbf{A} , $a_i \leq a_{i+1}$. Formalmente:

$$TOrder(\mathbf{A}) = \{ Perm(\mathbf{A}) \mid a_i \leq a_{i+1}, \forall i \} \quad (5.1)$$

Esta transformação é não linear e pode ser inversível desde que se mantenha a posição dos elementos onde se encontravam antes da permutação. Ela pode ser vista como uma transformação não linear do sinal.

A ordenação do sinal vem em busca da forma para facilitar o reconhecimento e a percepção. Porém, não se pode esquecer que a forma equivale a uma diminuição da informação contida no estado desordenado.

Por exemplo, nos sinais do eletroencefalograma, os dados são muito complexos, a quantidade de informação que eles transmitem é muito grande. Mas, ao ordenar os sinais encontra-se a *forma*, requerida pela TI. Na Figura 5.2, no lado esquerdo, tem-se o sinal provindo de um canal de EEG. Estes sinais são bastante complexos, aperiódicos. No momento em que se ordenam esses sinais (lado direito da Figura 5.2) obtém-se uma curva (forma).

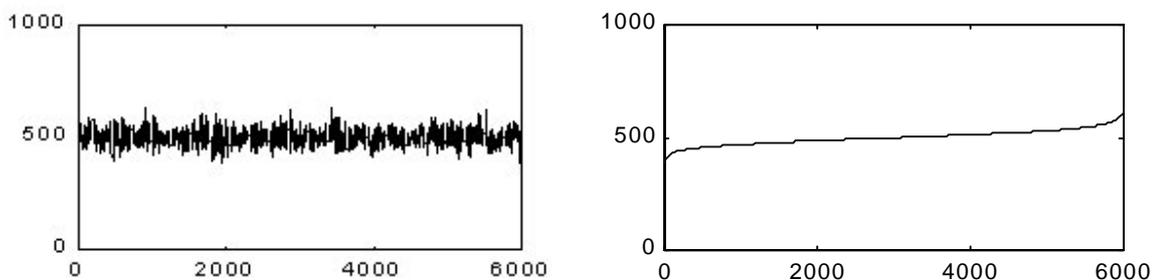


Figura 5.4 – Ordenação de uma amostra do sinal do canal C3 do EEG

Ao aplicar a *TOrdem* nos sinais referentes a cada estágio do sono observou-se que os gráficos dos sinais ordenados diferiam de um estágio para outro. A ordenação fornece uma padronização distinta dos sinais para cada estágio do sono. Analisando a Figura 5.3 vê-se duas fases do sono e seus dados ordenados (para uma amostra de 30 segundos). Neste caso, o subconjunto A possui 6000 elementos, pois para cada segundo de EEG tem-se 200 valores.

Observando os gráficos acima, conclui-se que a *TOrdem*, poderá ajudar no estagiamento automático do sono. Ela servirá como um pré-processamento para o uso das redes neurais para a classificação.

Observando as figuras do sinal e a sua ordenação, fica claro que o sinal ordenado é mais fácil de reconhecer que o sinal original, principalmente para os seres humanos. Isto vêm de encontro com a TI, quanto maior a desordem maior quantidade de informação. Mas por outro lado para se ter o significado necessita-se da forma, da redundância. Como no caso dos sinais a quantidade de informação que eles contém é muito maior do que o que se necessita, a idéia de buscar a forma através da ordenação realmente poderá ser muito útil para a classificação dos sinais (reconhecimento).

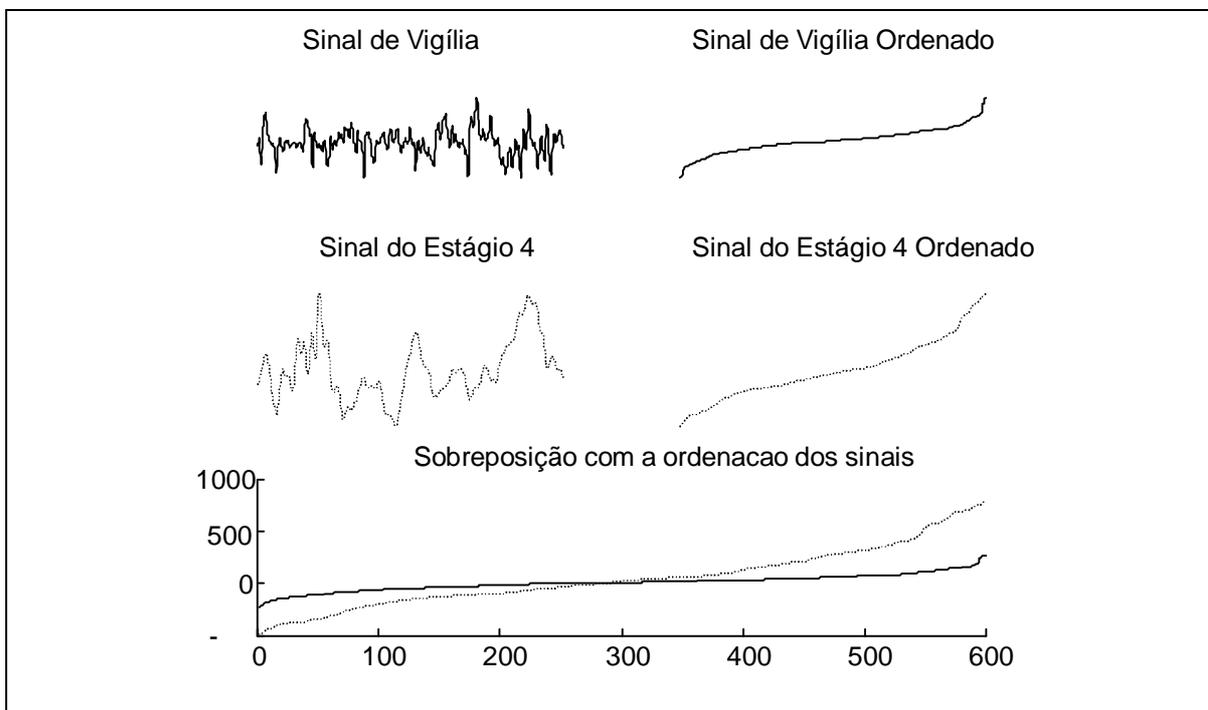


Figura 5.5: Mostra o efeito da ordenação dos sinais para a fase acordado (vigília) e o estágio 4 do sono NREM (utilizando uma amostra de 3 segundos)

O pré-processamento de sinais é um trabalho difícil, pois, como se pôde observar, existem muitas informações a disposição e deve-se extrair o suficiente para habilitar a tarefa

desejada. Esta seção ressalta a importância da forma na informação para a sua apresentação às redes neurais.

A *TOrdem* simplifica a forma do sinal e fornece uma padronização diferente para cada classe. Ela é uma transformação não linear e inversível que pode prover um bom pré-processamento para sinais digitais.

Esta abordagem será utilizada como parte do pré-processamento do sinal C3 do EEG, para a classificação automática do sono (Capítulo 6).

5.4 O classificador Mapa FAN

O Mapa FAN foi desenvolvido com intuito de sanar a principal limitação do FAN (Raittz, et al. 1998): a explosão combinatorial decorrente de problemas que apresentam alta dimensão. As filosofias subjacentes do FAN e do Mapa FAN são muito semelhantes. Por isso, antes de definir o mapa FAN, descreve-se sucintamente, nesta seção, o sistema híbrido FAN, que serviu de base para o desenvolvimento do classificador Mapa FAN.

5.4.1 FAN

Free Associative Neurons (FAN) é um exemplo de sistema híbrido. A base do FAN é as redes conexionistas, modelagem difusa e representação de padrões. FAN é baseado na noção do aprendizado neural; utiliza técnicas de conjuntos difusos para promover a granularidade de informações; e permite incluir diferentes métodos de associação de padrões para melhorar a sua capacidade de aprendizado (Raittz, et al. 1998).

A motivação para o desenvolvimento de FAN foi elaborar um método capaz de simular abstrações. Devido a esta capacidade cognitiva, os seres humanos compreendem um cenário completo baseados apenas nas partes que o compõem. De fato, na linguagem natural as pessoas resumem a informação, classificando objetos em estruturas de categorias de similares (palavras), evitando a sobrecarga de dados (Zadeh, 1996). Em FAN, a noção de classificação de padrões é feita por três processos: (a) expansão do espaço de entrada; (b) projeção da vizinhança do padrão resultante; (c) quantificação e aprendizado do grau de similaridade entre as classes FAN e as projeções dos padrões.

Em FAN, cada padrão de entrada é expandido em uma vizinhança difusa. Cada conjunto suporte dessa vizinhança é a combinação dos valores das características próximos dos originais. O grau de similaridade entre a vizinhança difusa e o padrão original de entrada é feito através das técnicas utilizadas na teoria dos conjuntos difusos. O aprendizado acontece através da projeção de toda a vizinhança difusa no espaço FAN. Existe uma unidade FAN (representado por uma matriz) para cada classe do domínio do problema. Cada unidade é uma grade composta por todas as combinações de características observadas em sua classe correspondente. Durante o treinamento, cada combinação é representada por uma célula difusa que contém um peso correspondente à sua frequência de ocorrência e grau de pertinência. O treinamento é baseado no reforço na célula (se a classificação foi correta) ou em esquecimento (se houve uma classificação incorreta) (Raittz, 1997).

FAN foi aplicado em diversos problemas práticos. Os resultados obtidos em três problemas de classificação (Raittz, 1997): (a) Os dados da IRIS de Fisher; (b) Classificação de cromossomos, segundo o grupo de Denver, com os dados de Copenhagen; e (c) Diagnóstico financeiro de empresas baseados em testes financeiros (Dandolini, 1997), foram comparáveis, aos melhores resultados encontrados com outros sistemas.

A principal característica observada nestas aplicações é a capacidade de descobrir gradualmente as classes. FAN define as classes durante a primeira época de treinamento. Ou seja, ele reconhece uma classe antes mesmo de processar todo o conjunto de treinamento. Esse comportamento parece indicar que o treinamento em FAN ocorre com crescente capacidade de generalização. As unidades FAN acumulam conhecimento durante o processo de treinamento de forma que as modificações nos pesos se tornam progressivamente menores. Em grandes conjuntos de treinamento, os últimos padrões são vistos mais como dados de teste, causando modificações muito pequenas no sistema.

Os resultados obtidos usando FAN são comparáveis aos métodos tradicionais de redes neurais, em termos de classificação e superior em termos de estabilidade no aprendizado e capacidade de generalização (Dandolini, 1997).

A grande limitação do FAN é a explosão combinatorial dos dados que decorre da granularização das características. Por exemplo, para cada padrão de entrada com três

características podem ser gerados 3^3 sub-padrões²⁵ com três características. Devido a esse problema é inviável usar FAN em problemas de alta dimensão, como é o caso das imagens.

5.4.2 O Mapa FAN

O FAN foi desenvolvido com a finalidade de resolver problemas de reconhecimento de padrões onde a quantidade de características, que representa cada padrão, é pequena. O Mapa FAN é uma variação do FAN em relação à forma de tratar o padrão de entrada. O objetivo é evitar a explosão combinatorial que ocorre no FAN, tornando possível a sua utilização em problemas multidimensionais (como, em reconhecimento de voz, em classificação de imagens de satélite e na classificação dos estágios do sono).

Os Mapas FAN são matrizes bidimensionais ($d \times n$), onde uma dimensão se refere às amplitudes dos sinais e a outra a ordem do sinal amostrado. Para cada classe é criado um Mapa FAN. Cada padrão de entrada é apresentado ao Mapa FAN que representa a classe do padrão. Desta forma tem-se um processo de aprendizagem supervisionado. O objetivo é modelar cada mapa com aspectos da classe que ele representa.

Um padrão a ser testado é apresentado a cada mapa treinado e este retorna o grau de pertinência daquele padrão em relação à classe que aquele mapa representa. O padrão de entrada será classificado de acordo com o maior grau de similaridade (pertinência).

5.4.2.1 Treinamento dos Mapas FAN

Defini-se em primeiro lugar as dimensões dos mapas, d , o número de linhas e n , o número de colunas. Esses parâmetros dependem dos dados com o qual se está trabalhando. O número de linhas (d) refere-se à amplitude do sinal, ou mais especificamente da normalização realizada no pré-processamento. O número de colunas (n) é o número de entradas de cada mapa (características que representam o padrão de entrada).

As entradas para o Mapa FAN são P e $Clas$, onde P é a matriz ($n \times 2$) que representa o padrão de entrada e $Clas$ a classe para o qual o padrão P pertence. Na matriz P , a segunda coluna se refere às amplitudes do sinal, que deverão ser normalizadas e truncadas entre os valores inteiros 1 e d (isto será detalhado no capítulo 6). A primeira coluna, indica a ordem das amplitudes (de 1 a n).

²⁵ Sub-padrão é um padrão com pertinência variada em relação ao padrão que o gerou.

Definida as dimensões, inicia-se o processo de aprendizagem dos mapas. O padrão de entrada P define as posições no mapa (posições da matriz), e a classe correspondente $Clas$ indica em qual mapa estas posições serão acessadas. Por exemplo, seja o padrão de entrada a matriz $P = \begin{bmatrix} 1 & 2 & 3 & 4 & 5 \\ 1 & 3 & 5 & 6 & 8 \end{bmatrix}^t$ e $Clas = C$ a classe que ele pertence, então as posições setadas no $Mapa_C$ são aquelas mostradas na Figura 5.6. A aprendizagem ocorre acrescentado-se um valor $\delta > 0$ fixo nas posições definidas pelo padrão de entrada (P). Este acréscimo refere-se ao estímulo ou reforço no processo de aprendizagem.

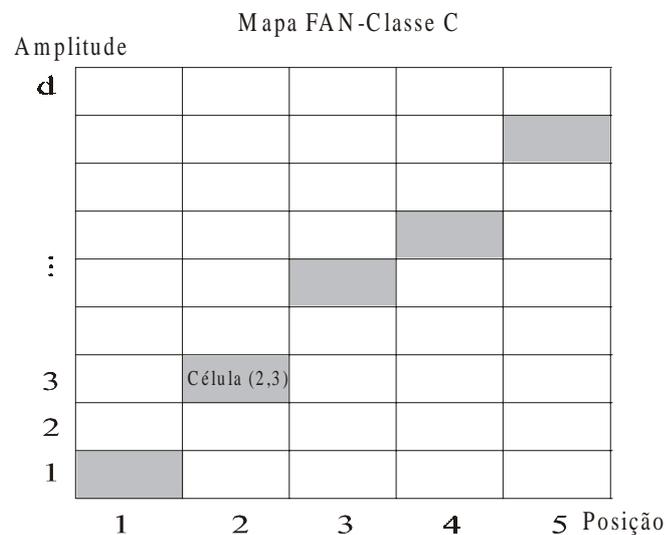


Figura 5.6: Aprendizagem no $Mapa_C$ indicada pela matriz do padrão de entrada

No final do processo de aprendizagem uma normalização é realizada em cada mapa segundo a quantidade de acessos realizados. Cada padrão de entrada é apresentado ao Mapa FAN somente uma vez.

5.4.2.2 Teste

A fase de testes, segue o mesmo raciocínio utilizado no FAN (Raittz et al, 1998). Para cada padrão a ser testado é gerada uma matriz de entrada P a qual definirá as posições dos Mapas que serão setadas. Definidas as posições, para cada Mapa treinado é feita uma verificação de pertinência com esta matriz de entrada de acordo com o nível de ativação que cada célula acessada possui, ou nível de reforço adquirido no processo de aprendizagem. A similaridade é calculada segundo a intersecção da ativação que cada mapa contém nas posições setadas pelo padrão de entrada (matriz de entrada). A quantidade de reforço

adquirida pelo mapa no processo de aprendizagem determina a resposta do mapa para com a entrada. Assim, tem-se um vetor de respostas, chamado vetor de pertinência da entrada P com os Mapas treinados.

O cálculo da pertinência entre uma matriz de entrada P (gerada a partir de um padrão de entrada) e o Mapa_C, podem variar entre uma aplicação e outra, ou depender da matriz de entrada P. As equações apresentadas na seqüência são as mesmas utilizadas na aplicação do Estagiamento Automático do Sono (Capítulo 6).

A pertinência entre P e o Mapa_C é dada por:

$$Pert(P, Mapa_C) = 1 - \prod_{j=1}^n \left(1 - \frac{P^{(i,j)} * Mapa_C^{(i,j)}}{\sum_{i,j} Mapa_C^{(i,j)}} \right) \quad (5.2)$$

onde $P^{(i,j)}$ é uma célula da matriz de entrada (posição da matriz), $Mapa_C^{(i,j)}$ são as respectivas posições no Mapa_C e o $\sum_{i,j} Mapa_C^{(i,j)}$ é todo o acúmulo de ativação adquirido pelo Mapa_C durante o processo de treinamento supervisionado.

A Equação 5.2 mede o grau de pertinência ou similaridade da matriz de entrada P com o Mapa FAN representante da classe C. Ela representa o uso da definição de complemento de conjuntos para escolha entre classes. A idéia está em concordância com o fato que: é mais fácil dizer o que não é, do que afirmar o que realmente é, ou seja, é mais fácil eliminar o errado que escolher o certo. O produto $P^{(i,j)} * Mapa_C^{(i,j)}$ realizado na fórmula 5.2 representa uma forma de realizar a intersecção de acordo com a teoria dos conjuntos difusos. Assim para cada entrada P, obtém-se o vetor de pertinências $VetPert(P)$, com relação a cada Mapa treinado, dado por:

$$VetPert_k = Pert(P, Mapa_k) \quad (5.3)$$

onde $k = 1, \dots, M$ e M é o número de mapas.

Assim, a classe do padrão P indicada pelo modelo é o índice do vetor $VetPert$ com maior pertinência. Ou seja, a classe do padrão P indicada pelo modelo é dada por:

$$ClasInd_p = \text{Índice} \left[\max_k (VetPert_k) \right] \quad (5.4)$$

onde k varia segundo a quantidade de classes.

A Figura 5.7 mostra a idéia do procedimento de verificação do nível de similaridade entre uma entrada P e um Mapa treinado. Quanto mais escuras forem as células, maior é o grau de reforço (ativação) que esta célula recebeu durante o treinamento. Os quadrados com borda são as posições indicadas pelo padrão P para a verificação da similaridade.

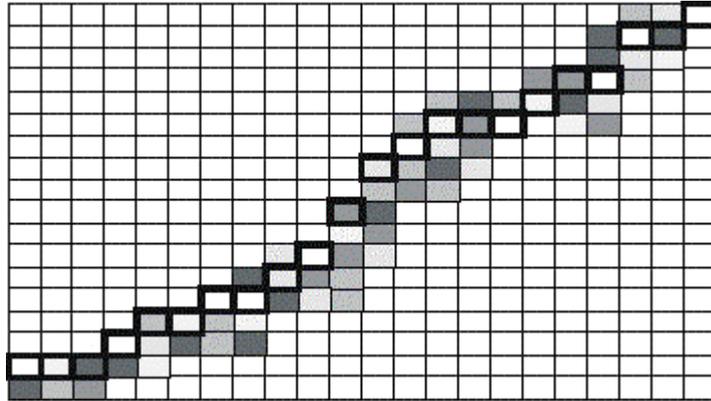


Figura 5.7: Intersecção entre um padrão de entrada (quadrados pequenos com bordas) e um mapa treinado (onde o nível de cinza caracteriza o grau de reforço de uma célula)

Observando a Figura 5.7, pode-se concluir que cada célula no mapa pode ser considerada como um neurônio e o tom de cinza seu nível de ativação.

Nota-se também que com o Mapa pode-se tratar com padrões de dimensão tão alta quanto o limite de máquina (tempo de processamento). Para isso, basta definir n (número de colunas da matriz) como sendo a dimensão do problema em questão.

5.5 Mapa FAN x FAN

Como o Mapa FAN derivou do FAN existem entre eles algumas semelhanças e algumas diferenças.

As diferenças principais com o FAN estão na:

- 1) granularização, onde as características eram expandidas, aqui se tem padrões com o número de características muito grande, uma granularização poderia levar a uma explosão combinatorial;
- 2) dimensão utilizada para a granularização interna (combinações das características) que dependia da quantidade de características que os padrões possuíam;

- 3) fase de treinamento, onde o armazenamento era feito por conjunção de pertinências parciais derivadas da granularização interna e externa;
- 4) na dimensão dos mapas, para o Mapa FAN, a matriz é bidimensional e para o FAN a dimensão da matriz depende do número de características dos padrões.

Portanto, a diferença está na forma de utilizar os padrões de entrada. Aqui o padrão é visto como tendo um excesso de informação, não é utilizada a informação espacial das características que compõem o padrão, informação esta responsável pelo aprendizado do FAN.

No Mapa FAN, assim como no FAN, cada classe de padrões é representada por um mapa discreto (matriz). O Mapa FAN, também tem em comum com o FAN a forma de realizar os testes, ou melhor, a forma como é calculada a similaridade entre um padrão de teste e os Mapas treinados para a sua classificação.

5.6 Conclusões

Este capítulo apresentou um novo sistema de classificações de padrões com a finalidade de tratar com padrões multidimensionais. Mais especificamente sinais digitais amostrados temporalmente, ou seja, dependentes de frequência e tempo de cada amostra.

No pré-processamento dos sinais a ordenação ressalta a importância da forma na informação para a sua apresentação às redes neurais de uma forma geral. A *TOrdem* simplifica a forma do sinal e fornece uma padronização diferente para cada classe. Ela é uma transformação não linear e inversível que pode prover um bom pré-processamento para sinais digitais.

O classificador Mapa FAN é baseado na tecnologia de redes neurais artificiais, principalmente na rede Híbrida FAN. Uma característica importante é a forma de utilizar os padrões de treinamento e de teste. O padrão é visto como um conjunto de elementos, e não é utilizada a informação espacial das características que compõem o padrão. Existe um Mapa para cada classe. Cada Mapa pode ser visto como uma rede de neurônios. A forma de calcular a similaridade entre um padrão de teste e os Mapas treinados segue o princípio em que quanto maior o nível de ativação maior a similaridade.

O modelo também está relacionado com conceitos da teoria dos sistemas difusos, mais especificamente no cálculo da similaridade realizado para obter o grau de ativação de uma entrada com o Mapa treinado.

O capítulo 6 apresenta a aplicação do sistema Mapa FAN no problema do estagiamento automático do sono.

6

Estagiamento Automático do Sono

6.1 Introdução

Este capítulo apresenta a arquitetura do sistema Mapa FAN, com as etapas do pré-processamento, o classificador Mapa FAN e o pós-processamento para o estagiamento automático do sono. Apresenta, também o desempenho do sistema quanto ao estagiamento automático do sono usando os dados do canal C3 do EEG de 7 pacientes, após o sistema ter sido treinado com os dados de um paciente.

A segunda seção faz referência a outros estagiadores do sono, com as técnicas que eles utilizam e o desempenho por eles alcançados. A seção seguinte apresenta as etapas do pré-processamento dos dados: o corte, a ordenação e a extração de características e o pós-processamento. Na quarta seção tem-se o as características do software desenvolvido. Os vários testes realizados, os resultados obtidos e a análise destes resultados são apresentados na seção seguinte.

6.2 Estagiadores do Sono

Além das técnicas baseadas em métodos estatísticos para estagiar o sono automaticamente, muitos pesquisadores têm utilizado o aprendizado indutivo para construir árvores de decisão e classificadores baseados em regras, como é o caso do sistema especialista para a realização do estagiamento proposto por Ray et al. (1986).

Um exemplo da utilização de RN é o trabalho apresentado por Nielsen et al. (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 al. usaram o estagiamento visual realizado por dois especialistas como referência. Os resultados obtidos por Nielsen tiveram uma concordância de 68% a 71%.

Algumas RN também têm sido utilizadas para classificação do sono partindo de treinamentos realizados com exemplos selecionados, como é o caso do trabalho de Schaltenbrand (1995) e Lossmann (1996), que utilizou redes neurais de Kohonen para produzir um semi estagiamento segundo critérios próprios.

O trabalho de Oropesa et al. (1999) utiliza as transformadas de Wavelets para transformar os sinais no domínio do tempo-freqüência, um gerador de características que quantifica a informação e reduz a dimensão do conjunto de dados, e uma RN Backpropagation para a classificação. A rede é treinada com 200 amostras de 30 segundos de quatro fases do sono: Vigília, REM, estágio 1 e Estágio2 (os estágios 3 e 4 não foram usados). A rede é testada com outro conjunto de dados, que contém também 200 amostras de cada fase. O nível de concordância com o especialista humano alcançado foi de 70 a 80 %.

Os trabalhos de Tafner (1999) e Souza (1999) também utilizam um gerador de características e uma RN no estagiamento do sono. O trabalho de Souza apresenta uma forma alternativa de redução de dimensionalidade, que é utilizada na geração de características dos dados do canal C3 do EEG. Estas características são utilizadas como as entradas para a rede ARC (Alta Representação Cortical), desenvolvida por Tafner. Neste caso, a rede é treinada com amostras de 30 segundos com dados de um paciente e testada nos dados de outros 3 pacientes. Os dados foram classificados em quatro classes, sendo: Vigília, Estágio 1/2, Estágio 3/4 e REM. Aqui os resultados alcançaram uma taxa de reconhecimento entre 60 e 76 %.

Um outro trabalho que utiliza técnica de IA, é o trabalho de Mota et al. (1999). Eles utilizam um classificador difuso onde os parâmetros são ajustados por um algoritmo genético. O sistema de Mota extrai 12 características do canal C4 do EEG que são as entradas do classificador difuso. Os dados são classificados em quatro estágios, sendo: Vigília, Estágio 2, Estágio 3/4 e REM/Estágio1. Os resultados obtidos variam de 60 a 80 % de acerto.

6.3 Sistema Proposto

O sistema desenvolvido para o estagiamento do sono é composto de três etapas, sendo: pré-processamento do sinal, o classificador Mapa FAN e o pós-processamento. A Figura 6.1 ilustra a arquitetura do sistema.

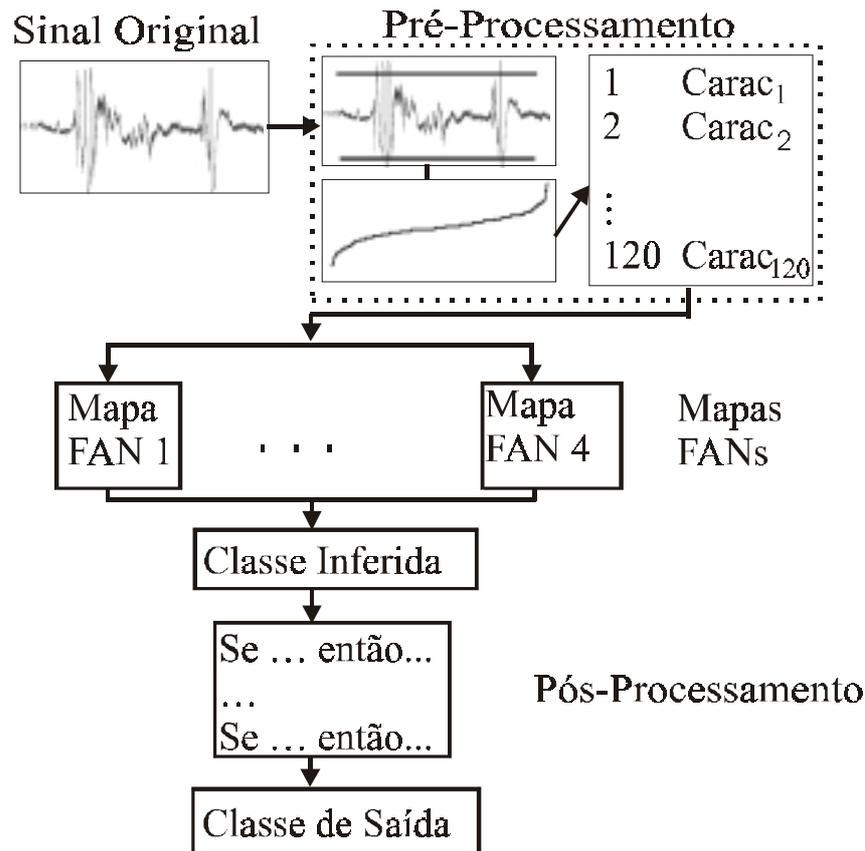


Figura 6.1 : Arquitetura do Sistema Mapa FAN para o Estagiamento Automático do Sono

6.3.1 Pré-processamento dos Dados

Os dados são submetidos a três 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 consiste, então, em 3 fases diferentes, cada uma das quais fornece à informação biológica adquirida uma nova forma. A atuação de uma fase sobre os resultados obtidos na fase anterior constitui o processamento para este trabalho. As fases são assim denominadas:

- Ajuste do Sinal Biológico
- Ordenação do Sinal
- Redução da Dimensão da Amostra (extração de características).

6.3.1.1 Ajuste do Sinal Biológico

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, devidos possivelmente a algum movimento do paciente ou problemas inerente do aparelho) 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). A Figura 6.2 ilustra o corte realizado no sinal. Após os sinais serem ajustados aos novos limites, converte-se todo o sinal negativo no seu simétrico²⁶.

6.3.1.2 Ordenação dos Sinais

Uma vez ajustados os sinais biológicos, estes são divididos em amostras (o tamanho da amostra, ou época utilizada é de 30 segundos²⁷, ou 6000 pontos). Cada amostra é então ordenada para que determinadas características possam ser extraídas. A ordenação dos sinais é realizada de acordo com a Equação (5.1). Dessa maneira tem-se o agrupamento dos sinais segundo suas respectivas amplitudes.

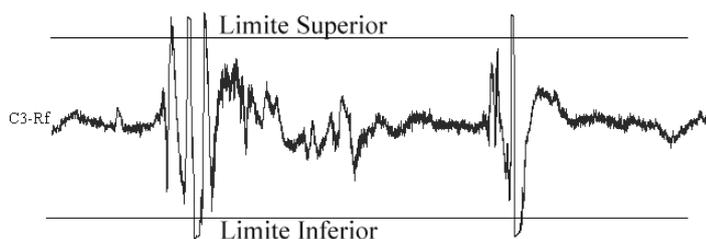


Figura 6.2: Trecho do sinal biológico original com o limite superior e o limite inferior

6.3.1.3 Extração das Características

Apresenta-se neste trabalho uma forma de extração de características para reduzir a dimensão. Esta redução é feita com o objetivo de purificar os dados de uma forma natural. Na

²⁶ Alguns pesquisadores têm utilizado uma fase extra para os sinais muito ruidosos (Mota et al., 1999).

²⁷ Os especialistas, geralmente, usam 30 segundos para realizar o estagiamento visual.

aplicação utilizada para a validação do modelo proposto, estagiamento do sono, tem-se uma alta dimensão em função do equipamento utilizado para a captura dos dados. Sabe-se que o cérebro transmite ondas que variam de uma frequência de 6Hz a 30Hz (canais do EEG), e como os dados são capturados a uma frequência de 200Hz, existe assim uma alta dimensionalidade inerente ao processo. A redução apresentada a seguir está direcionada para amenizar esse problema.

Cada amostra, após a ordenação, é dividida em n segmentos S_1, S_2, \dots, S_n (Figura 6.3).

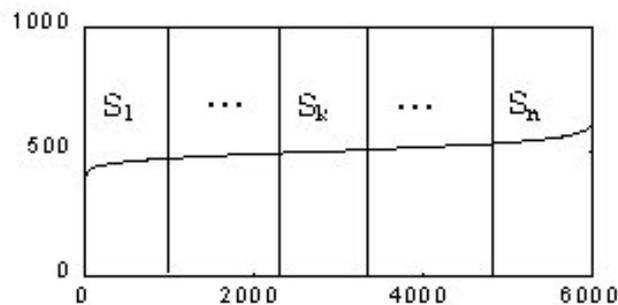


Figura 6.3: Divisão da amostra em n segmentos

Para cada segmento S_k , gera-se a característica $Carac_k$, tomando-se a parte inteira da média das amplitudes deste segmento. Ou seja, sendo m o tamanho da amostra e $VetAmp$ o vetor contendo as m amplitudes, então:

$$Carac_k = \text{ParteInteira}[\text{media}(\mathbf{VetAmp} (m*(k-1)/n + 1 \dots m*k/n))] \quad (6.1)$$

A outra característica é a posição (ou ordem) k do segmento. Então cada amostra do sinal biológico gera um padrão de entrada P para o Mapa FAN representado pela seguinte matriz:

$$P = \begin{bmatrix} 1 & \dots & k & \dots & n \\ Carac_1 & \dots & Carac_k & \dots & Carac_n \end{bmatrix}^t. \quad (6.2)$$

Observe que os elementos da matriz P são números inteiros pois eles vão indicar as posições que serão setadas no Mapa FAN.

Essa extração de característica difere do que é feito por outros pesquisadores. Por exemplo, em Mota et al. (1999) e Oropesa et al. (1999) a extração de características é feita

através da seleção de sub-bandas de frequência. Em Souza (1999) a extração de características é realizada através da partição do índice recursivo.

6.3.2 Pós-Processamento

O pós-processamento é baseado em um conjunto de regras de inferência *se....então*. Estas regras têm como objetivo corrigir as classificações erradas feitas pelos Mapas. As regras são construídas levando em conta alguns critérios sobre a evolução do sono durante a noite. Por exemplo, uma pessoa dormindo não passa da fase vigília para o estágio 4 diretamente. Gerando, assim a regra:

“Se classe anterior = *Vigília* por três amostras consecutivas e classe posterior = *Est4* então classe posterior = *Vigília*”

De forma semelhante, outras regras como: uma pessoa não passa de fase vigília para o estágio 3, ou, de vigília para o REM, diretamente.

O pós-processamento corrigiu algumas falhas do classificador aumentando o desempenho do sistema de 1 a 4% em média.

6.4 Software Desenvolvido

Para auxiliar os especialistas e/ou os neurofisiologistas, foi desenvolvido um protótipo que combina pré-processamento, extração de característica, classificador Mapa FAN e pós-processamento para a realização do estagiamento automático das fases do sono. Sua elaboração foi baseada na filosofia de desenvolvimento da orientação a objetos, procurando seguir uma metodologia de desenvolvimento que facilitasse alterações futuras. O software foi desenvolvido no ambiente de programação Delphi 4.0 e com a linguagem Object Pascal.

Como plataforma de desenvolvimento, adotou-se um computador da linha IBM-PC (Pentium II 300 MHz) com o sistema operacional windows 98.

6.4.1 Objetos do Sistema

O sistema de reconhecimento, chamado Estagiado Automático Mapa FAN, foi modelado de forma orientada a objetos resultando em uma estrutura onde o sistema é composto por três objetos principais, são eles: Mapa FAN, Processamento e Gerenciador.

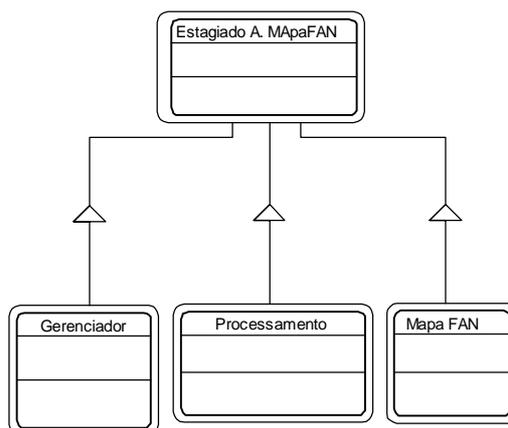


Figura 6.4: Estrutura Todo-Parte dos objetos do Protótipo Estagiador A. Mapa FAN

O objeto Gerenciador é quem coordena a troca de mensagens entre os objetos Processamento e Mapa FAN, 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 treinamento, a troca de mensagens pode ser vista como o repasse do *senal original* (registro 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 Mapa FAN. Feito isso, o Gerenciador envia a mensagem de *aprender* para o objeto Mapa FAN.

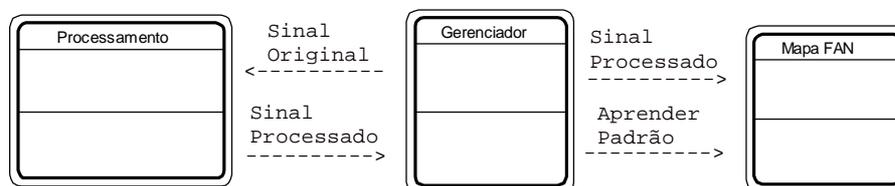


Figura 6.5: Troca de mensagens entre os objetos durante o treinamento

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 Mapa FAN. Feito isso, o Gerenciador envia uma mensagem ao objeto Mapa FAN solicitando a tarefa do reconhecimento do padrão. Respondendo à solicitação, o objeto Mapa FAN retornará o sinal classificado conforme o seu conhecimento adquirido durante a fase de treinamento.

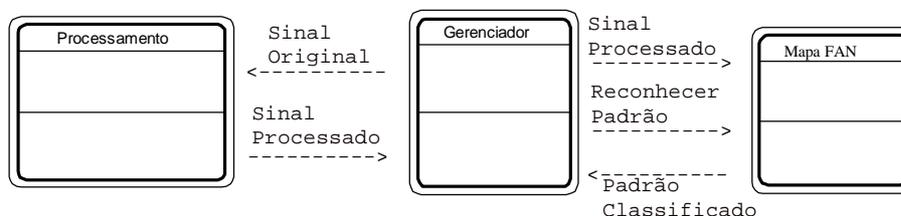


Figura 6.6: Troca de mensagens durante o reconhecimento

6.4.2 Protótipo – Estagiador Automático Mapa FAN

O Estagiador Automático está dividido em diversas tarefas, que por sua vez estão separadas em 3 diferentes painéis e um painel para indicar a fase de desenvolvimento do protótipo. O primeiro painel, chamado de *Preparar Canais*, é onde o sistema realiza a conversão do formato POLIWIN²⁸ do arquivo de exame para um formato próprio, desenvolvido para este fim.

²⁸ Formato de propriedade da empresa EMSA – Equipamentos Médicos S.A.

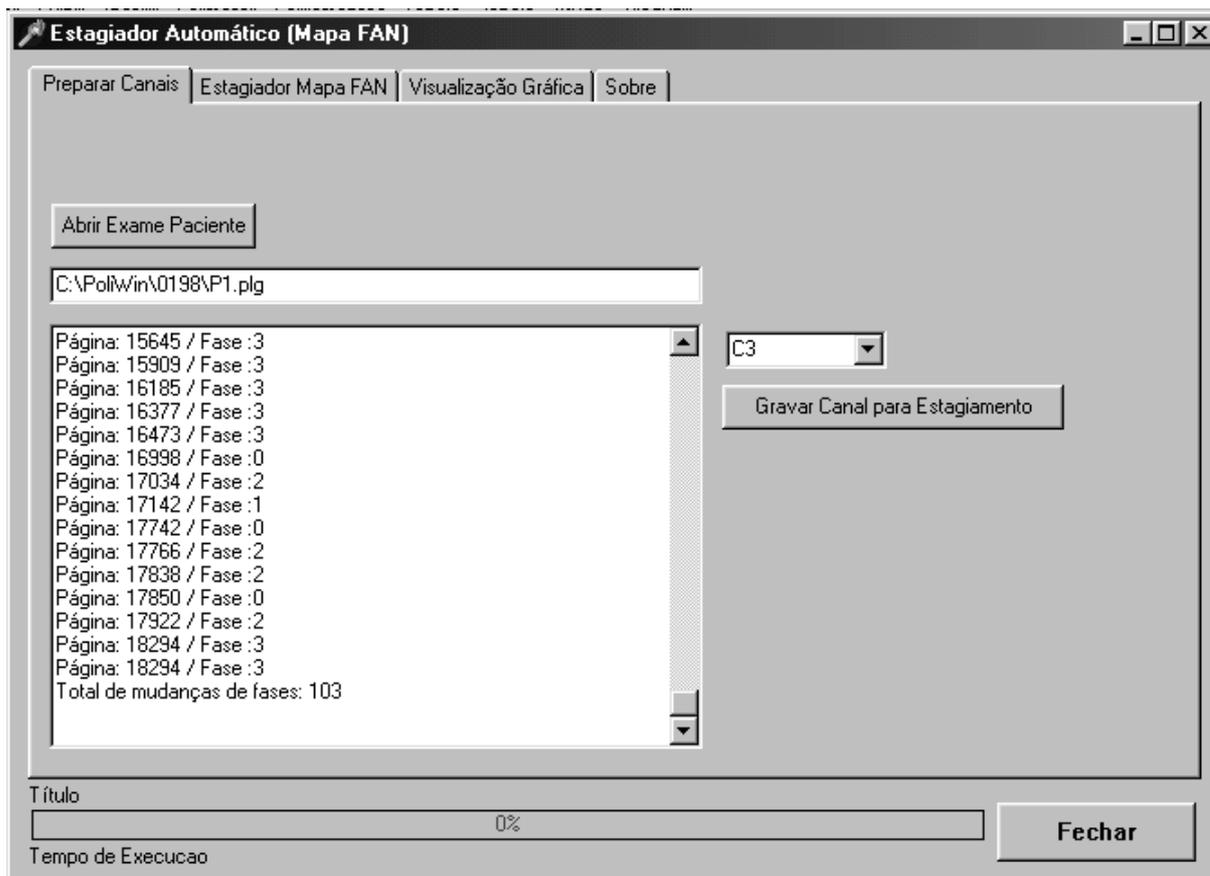


Figura 6.7: Painel de conversão de arquivos

Essa conversão é realizada com o objetivo de reduzir o tamanho do arquivo, uma vez que o sistema proposto utiliza somente um canal de registro, enquanto que o sistema POLIWIN utiliza até 32 canais diferentes. Antes de realizar a operação de conversão, pode-se escolher qual dos canais do EEG (registrados pelo POLIWIN) que será utilizado.

O segundo painel, *Estagiador Mapa FAN*, possui a tarefa de realizar o treinamento e o reconhecimento utilizando o arquivo preparado anteriormente (painel *Preparar Canais*). É neste painel também que se escolhe qual o exame que será manuseado tanto para o treinamento quanto para o estagiamento (testar). Uma vez treinado o sistema, este pode ser testado com qualquer outro exame selecionado.

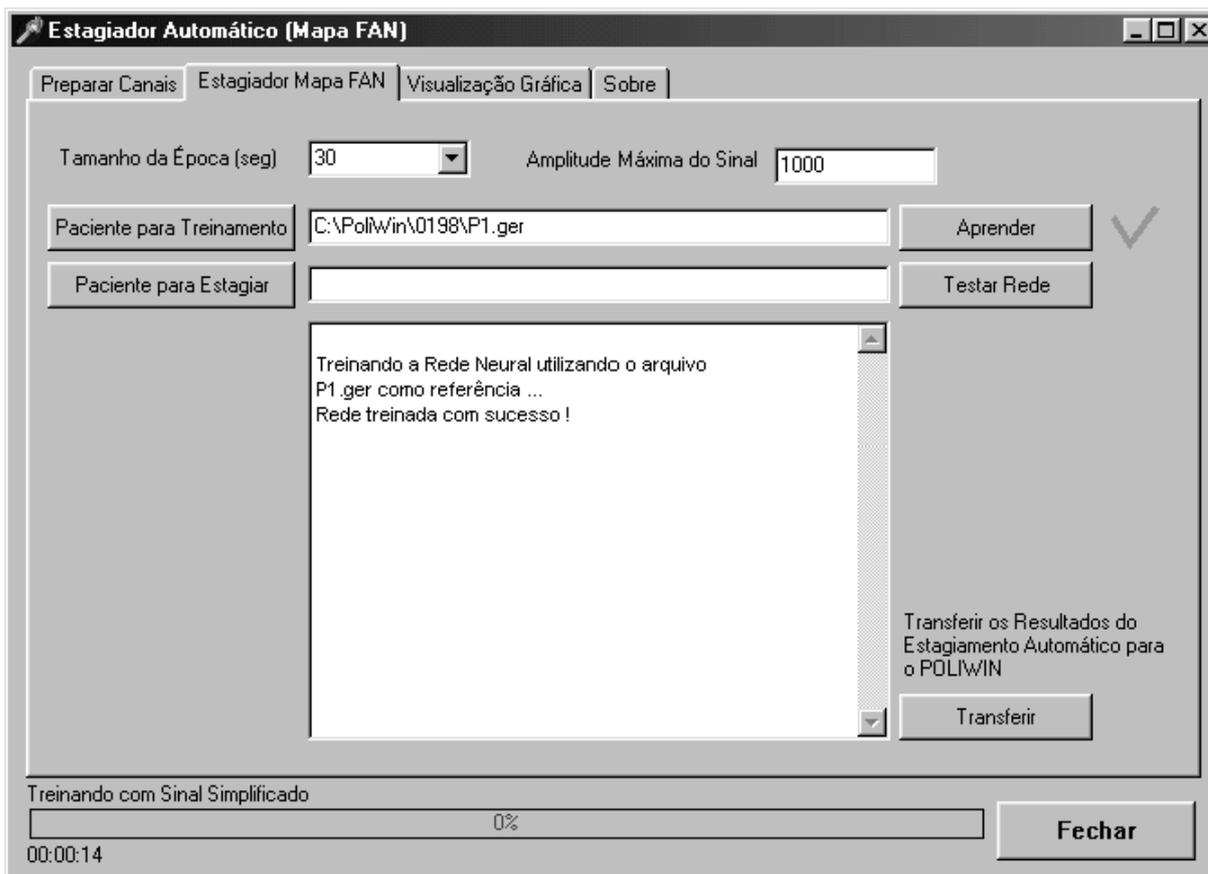


Figura 6.8: Painel Estagiador Mapa FAN realizando o treinamento

Neste painel também, têm-se duas variáveis de controle, o *Tamanho da Época* que pode ser escolhido como 30 segundos ou 15 segundos e a *Amplitude Máxima do Sinal* que delimita a máxima variação da amplitude. Quando é realizado o estagiamento (teste) é apresentado o percentual de acerto de cada fase, caso este paciente já tenha sido estagiado visualmente, caso contrário tem-se a opção de transferir o estagiamento automático para o sistema POLIWIN.

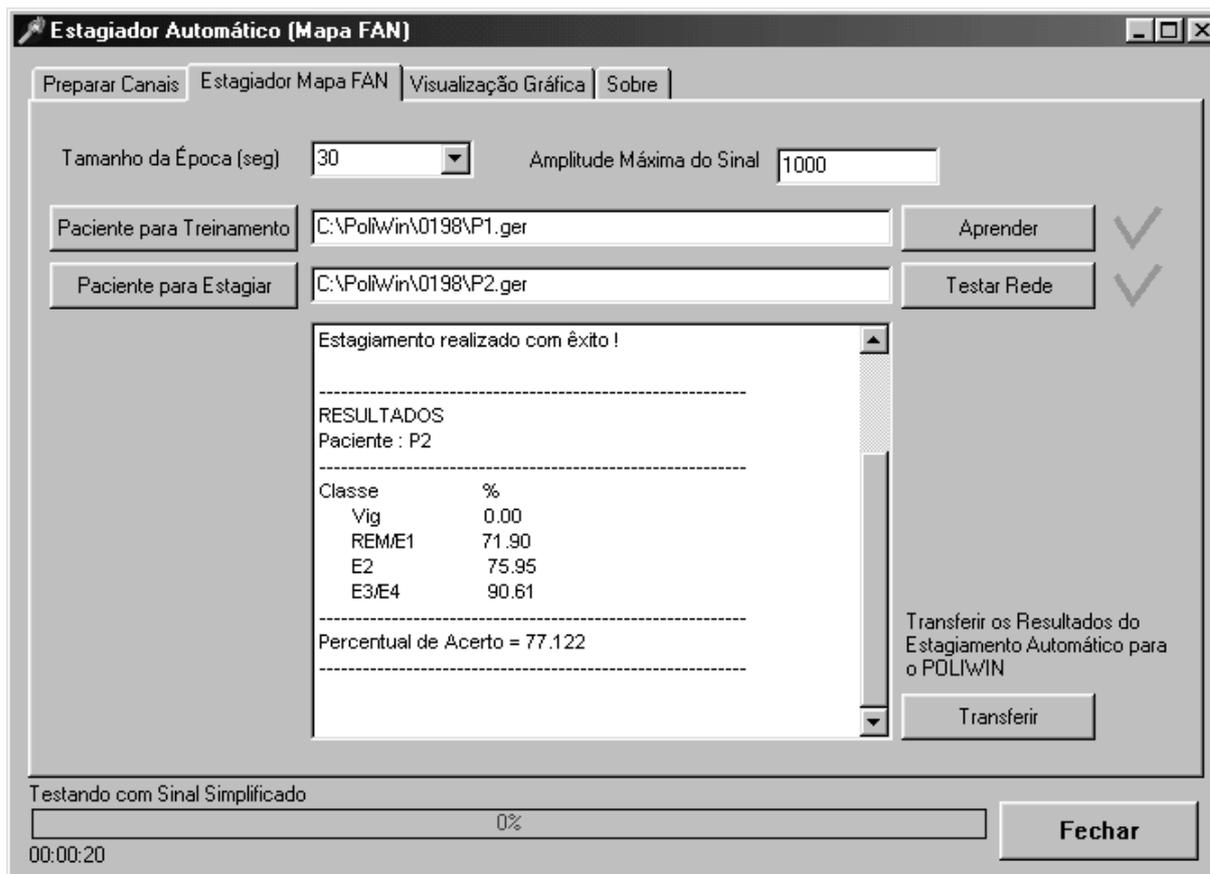


Figura 6.9: Painel Estagiador Mapa FAN realizando o teste

Finalmente, no painel 3 (*Visualização Gráfica*), é onde se pode visualizar o resultado da operação de reconhecimento executada no painel *Estagiador Mapa FAN*. Este painel tem o objetivo de apresentar os resultados para o especialista da área, apresentando o hipnograma e o histograma para que o mesmo tenha uma visão geral do exame.

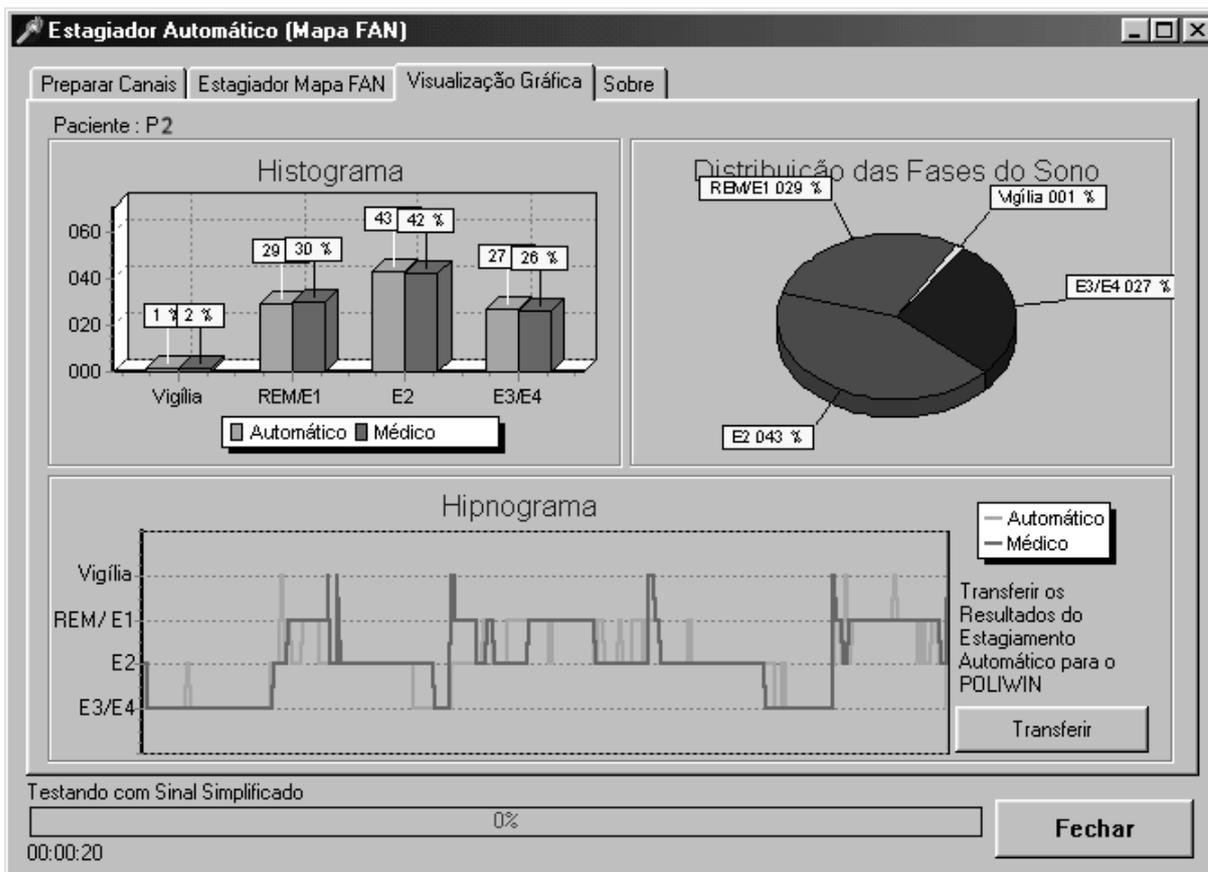


Figura 6.10: Painel dos resultados gráficos

6.5 Aplicação

6.5.1 Os dados

O sinal biológico utilizado para a realização do estagiamento automático é proveniente do eletroencefalograma, especificamente o canal C3, recomendado inclusive por Carskadon e Rechtschaffen (1994), onde ressaltam que as ondas usadas para distinguir os estágios são bem visualizadas utilizando os canais C3 e C4²⁹.

Para a aquisição do sinal eletroencefalográfico, utilizou-se o sistema de polissonografia digital POLIWIN³⁰, que funciona através de um microcomputador ligado a

²⁹ Os médicos quando fazem o estagiamento do sono utilizam todos os registros que o aparelho captura, incluindo diversos canais de EEG, o EMG e o EOG.

³⁰ O software POLIWIN foi desenvolvido pela empresa EMSA.

um equipamento de amplificação analógica. O sinal é adquirido a uma taxa de amostragem de 200 Hz. A taxa de quantização do sinal é fixa em 12 bits de precisão.

Para os testes, foram utilizados os exames de 8 pacientes jovens adultos (P1, P2, P3, P4, P5, P6, P7 e P8), sendo três do sexo feminino (Tabela 6.1). Os exames foram estagiados visualmente, de acordo com as regras de Rechtschaffen e Kales (1968), por um especialista em sono.

Neste trabalho, modificou-se a quantidade de classes do estagiamento automático. A modificação abrange, basicamente, os estágios 1, 3 e 4. Os estágios 3 e 4 foram agrupados em um único estágio. Essa decisão foi tomada uma vez que a separação destes estágios é arbitrária e pouco útil (Martinez, 1999). O estágio 1 foi somado junto ao estágio REM. Esta decisão foi baseada em Niedermeyer e Silva (1993). Desta forma, o sistema foi treinado e testado para classificar os dados em quatro classes, sendo: Vigília, Estágio1/REM, Estágio 2 e Estágio 3/4. O trabalho de Moura et al. (1999) também classifica do sono nessas quatro classes.

Tabela 6.1 – Pacientes

Paciente	Idade / Sexo	Tempo de Registro (horas)
P1	48 / M	03:53:05
P2	25 / M	05:47:58
P3	25 / M	07:35:43
P4	31 / M	07:36:40
P5	23 / F	07:31:09
P6	20 / F	07:21:44
P7	43 / M	06:36:07
P8	21 / F	07:36:54

6.5.2 Os parâmetros do Sistema

Para a construção dos padrões de entradas (Equação (6.2)), as fases do pré-processamento foram seguidas. Para a primeira fase utilizaram-se os limites, inferior e superior, em -1000 e $+1000$, respectivamente. Após o corte, os dados foram normalizados no intervalo $[0,1000]$. Para a segunda fase, a ordenação do sinal foi realizada em amostras de 30 segundos (6000 pontos). E finalmente, na terceira fase, para cada amostra foi gerada 120 características (uma a cada 50 pontos). Então, o padrão de entrada é:

$$\text{Padr\~{a}o_Entrada} = \begin{bmatrix} 1 & \text{Carac}_1 \\ \vdots & \vdots \\ 120 & \text{Carac}_{120} \end{bmatrix} \quad (6.3)$$

Foram criados 4 Mapas FAN, um para cada classe. Cada Mapa foi definido como uma matriz 1000x120.

O paciente P1 foi utilizado para o treinamento dos Mapas e os outros sete pacientes para testar.

A Figura 6.4 mostra uma vis\~{a}o tri-dimensional de 2 mapas treinados (Parte superior refere-se a classe REM/Est\~{a}gio 1 e a parte inferior a classe Vig\~{a}lia). Observe na Figura 6.4 as diferentes ativa\~{c}oes nas c\~{e}lulas dos Mapas.

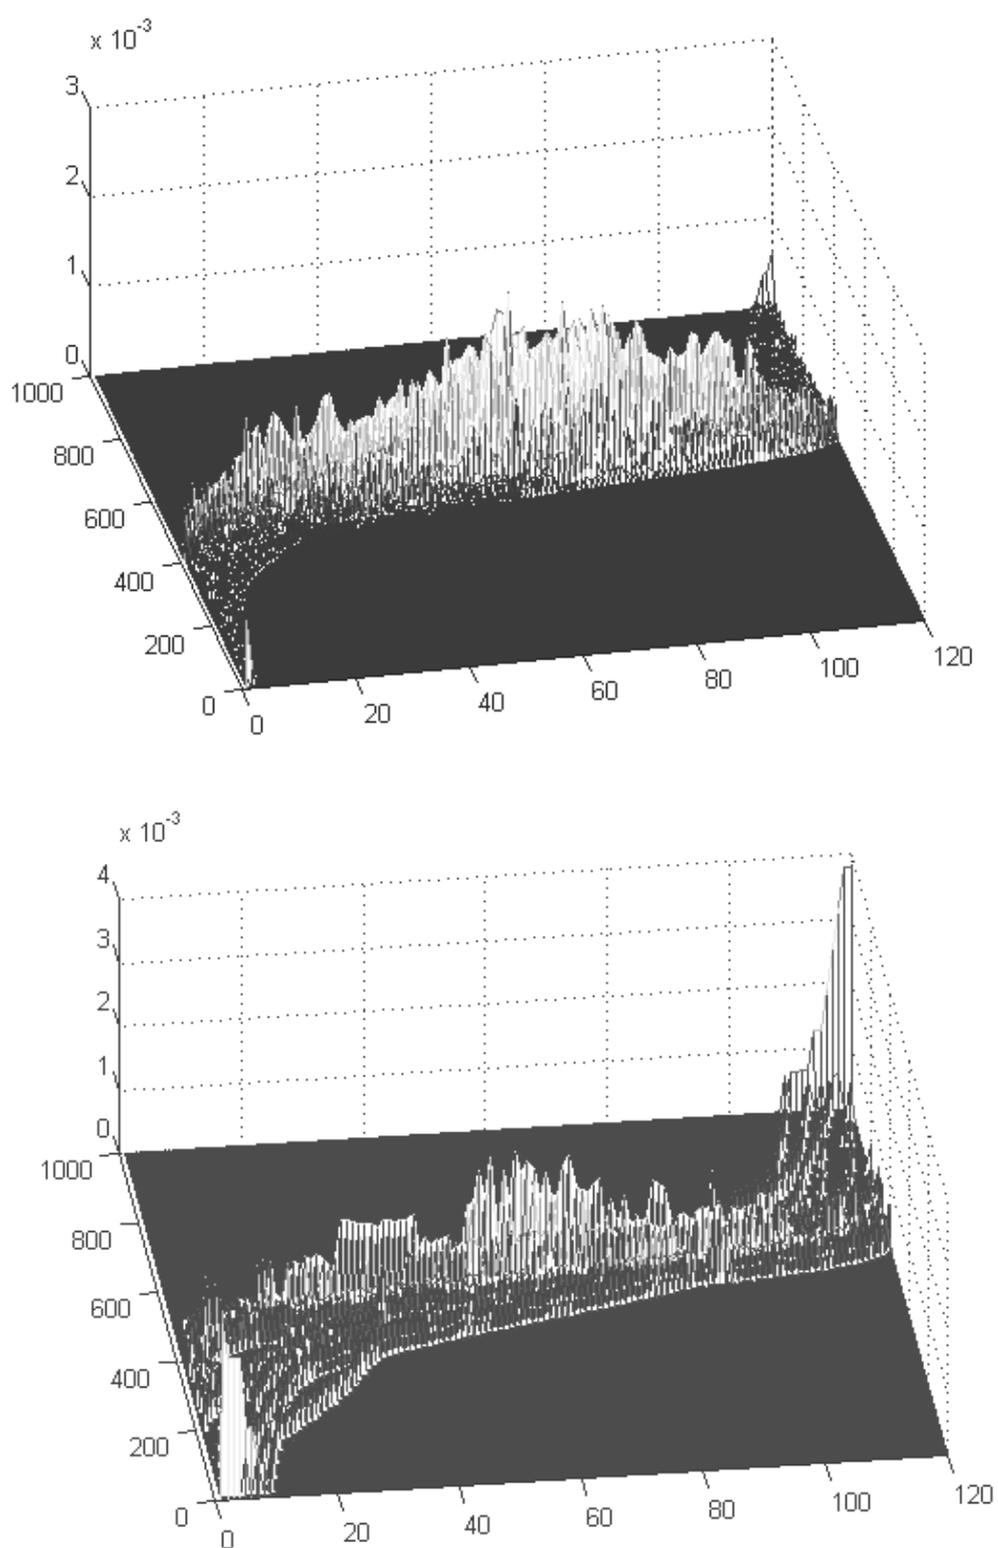


Figura 6.11: Visão tridimensional dos Mapas FAN treinados -Parte superior refere-se a classe REM/Estágio 1 e a parte inferior a classe Vigília

6.5.3 Resultados

O exame do paciente P2, submetido à análise do sistema treinado com o exame do paciente P1, obteve uma taxa de acerto de 77.12 % confrontado com o resultado do estagiamento realizado de forma visual. Já para o próprio conjunto de treinamento, paciente P1, o sistema teve uma concordância em torno de 87.55 %. A simulação segue a seguinte distribuição:

Tabela 6.2 - Distribuição do Acerto para o Paciente de treinamento (P1)

Classe	Sistema	Visual	Acerto (%)
Vigília	15	15	100.0
Estágio 1/REM	71	75	94.67
Estágio 2	130	149	87.25
Estágio $\frac{3}{4}$	192	227	84.58
Total	408	466	87.55

Tabela 6.3 - Distribuição do Acerto para o Paciente P2

Classe	Sistema	Visual	Acerto (%)
Vigília	0	13	0
Estágio 1/REM	151	210	71.90
Estágio 2	221	291	75.95
Estágio $\frac{3}{4}$	164	181	90.61
Total	536	695	77.12

O hipnograma com a apresentação simultânea do resultado do estagiamento automático (sistema) mais o estagiamento visual (médico), 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 nas figuras a seguir:

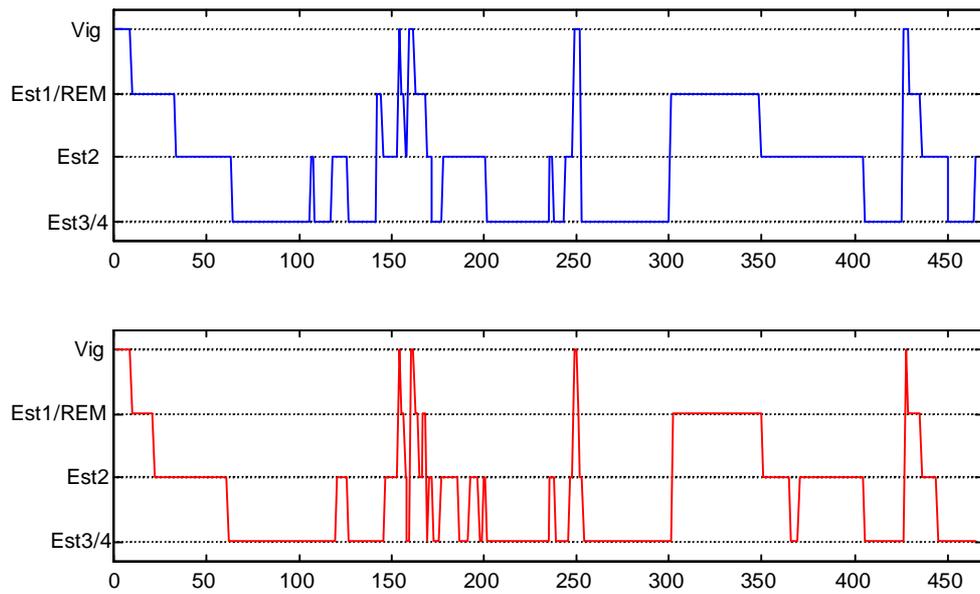


Figura 6.12: Parte superior apresenta o hipnograma do paciente P1 (paciente do treinamento) segundo o estagiamento do sistema e a parte inferior referente ao médico

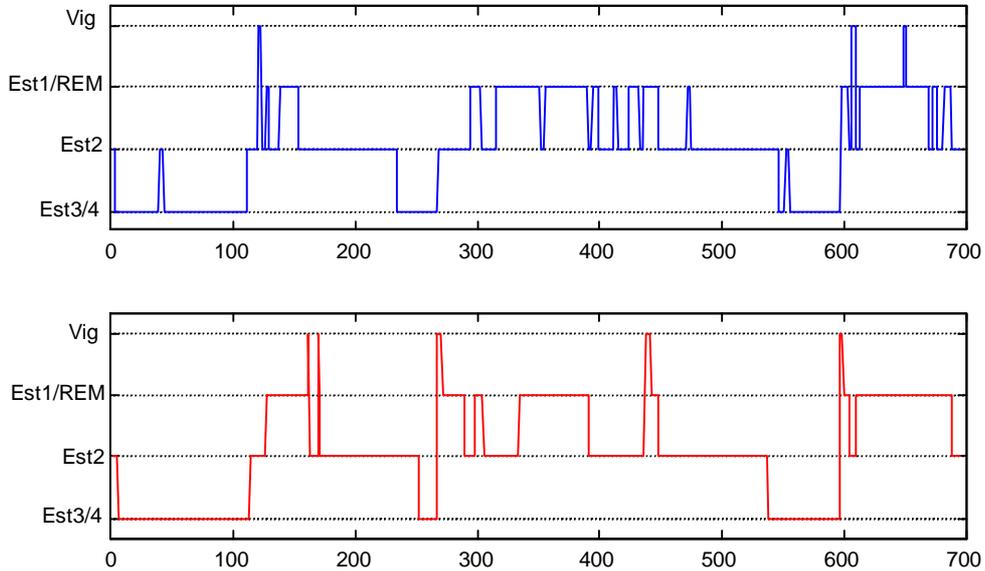


Figura 6.13: Parte superior apresenta o hipnograma do paciente P2 segundo o estagiamento do sistema e a parte inferior referente ao médico

Para os pacientes P3 e P4, pode-se observar os resultados (Tabela 6.4), e os hipnogramas (Figuras 6.14 e 6.15), também obtidos usando-se as mesmas configurações aplicadas ao exame P2.

Tabela 6.4 - Distribuição do Acerto para os Pacientes P3 e P4

Classe	P3			P4		
	Sistema	Visual	Acerto (%)	Sistema	Visual	Acerto (%)
Vigília	4	95	4.21	8	79	10.13
Estágio 1/REM	247	322	76.71	206	322	63.98
Estágio 2	216	403	53.60	261	319	81.82
Estágio 3/4	89	91	97,80	170	193	88.08
Total	556	911	61.03	645	913	70.64

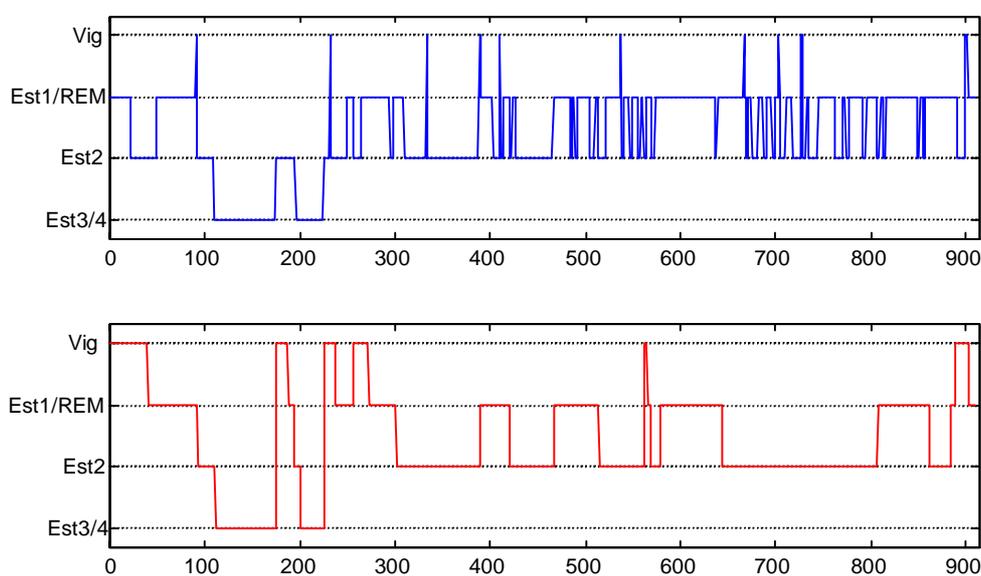


Figura 6.14: Parte superior apresenta o hipnograma do paciente P3 segundo o estagiamento do sistema e a parte inferior referente ao médico

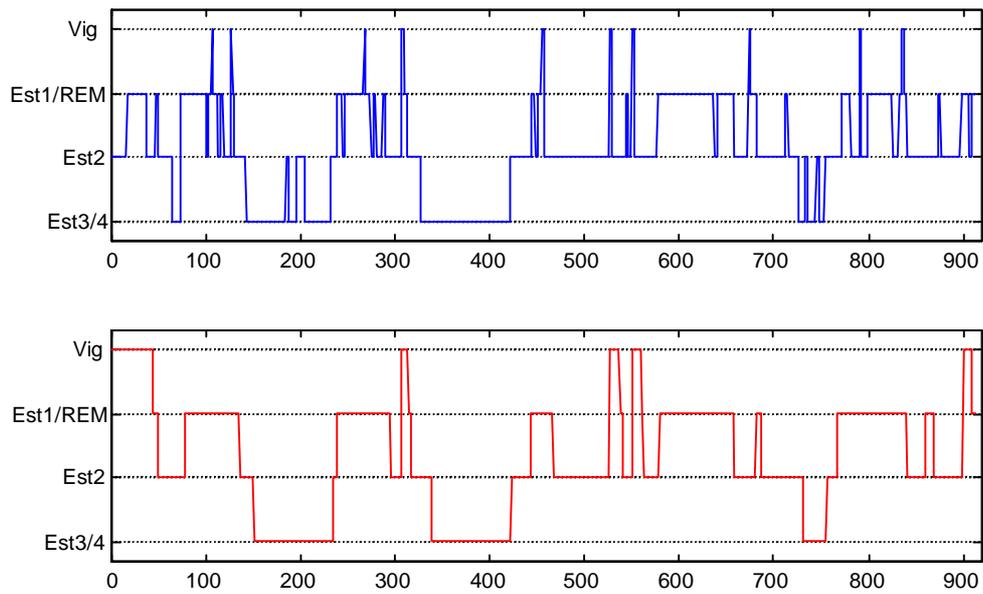


Figura 6.15: Parte superior apresenta o hipnograma do paciente P4 segundo o estagiamento do sistema e a parte inferior referente ao médico

Outra representação gráfica que pode vir a ser bastante útil é o histograma por classe, que apresenta a quantidade de tempo de cada classe por método (sistema e visual).

Gráfico 6.1 -Histograma mostrando a distribuição por classe do paciente P1

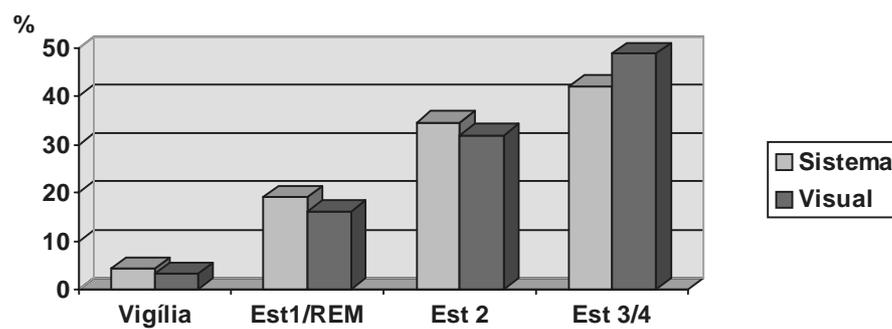


Gráfico 6.2 - Histograma mostrando a distribuição por classe do paciente P2

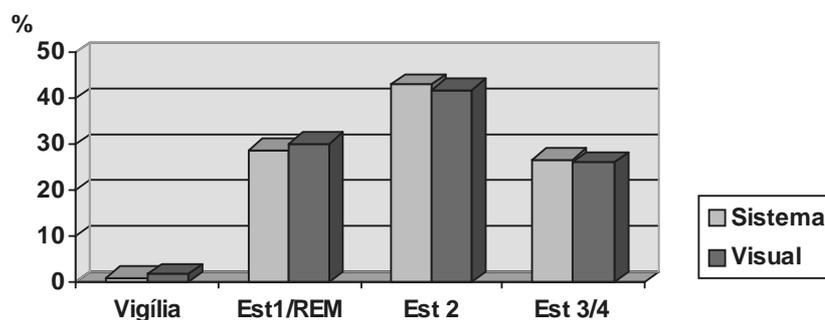


Gráfico 6.3 - Histograma mostrando a distribuição por classe do paciente P3

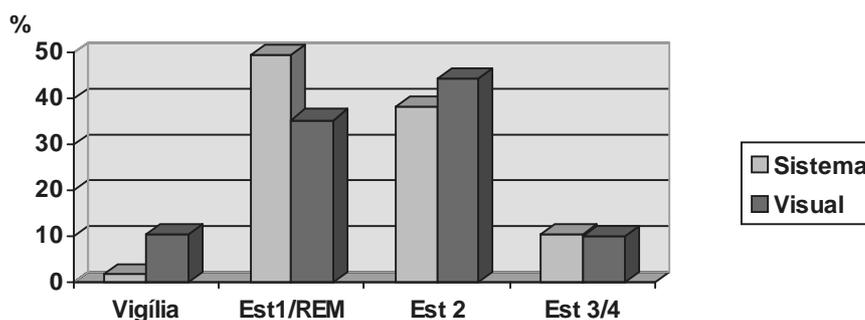
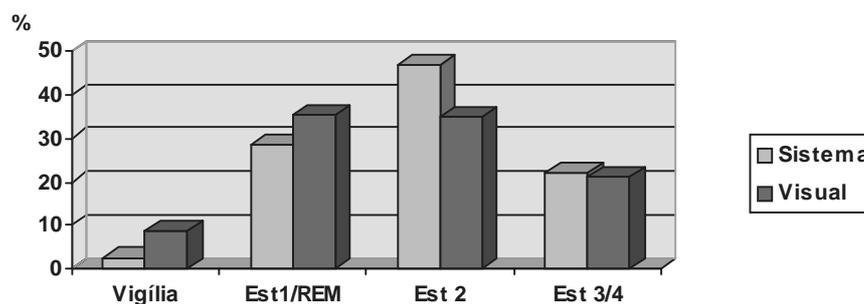


Gráfico 6.4 - Histograma mostrando a distribuição por classe do paciente P4



Para os outros pacientes, P5, P6, P7 e P8, pode-se observar os resultados obtidos usando-se as mesmas configurações aplicadas aos outros pacientes nas Tabelas 6.5 e 6.6.

Tabela 6.5 - Distribuição do Acerto para os Pacientes P5 e P6

Classe	P5			P6		
	Sistema	Visual	Acerto (%)	Sistema	Visual	Acerto (%)
Vigília	1	66	1.52	0	37	0.0
Estágio 1/REM	63	119	52.94	203	222	91.44
Estágio 2	382	463	82.51	355	470	75.53
Estágio 3/4	176	254	69.29	139	154	90.26
Total	622	902	68.96	697	883	78.93

Tabela 6.6 - Distribuição do Acerto para os Pacientes P7 e P8

Classe	P7			P8		
	Sistema	Visual	Acerto (%)	Sistema	Visual	Acerto (%)
Vigília	0	64	0.0	10	44	22.73
Estágio 1/REM	86	134	64.18	34	190	17.89
Estágio 2	428	537	79.70	264	435	60.69
Estágio 3/4	24	57	42.11	243	244	99.59
Total	538	792	67.93	551	913	60.35

Os resultados para os conjuntos de testes variaram, então, de 60 a 78 % de acerto e os hipnogramas e os histogramas ficaram semelhantes aos do especialista.

Outros testes utilizando outros pacientes para o treinamento foram realizados, os quais mostraram um desempenho semelhante. Por exemplo, a Tabela 6.7 mostra os resultados obtidos usando os dados do paciente P2 para o treinamento.

Tabela 6.7 - Distribuição do Acerto usando o Paciente P2 para o treinamento

Paciente	Acerto (%)
P1	68.02
P2 (Treinamento)	80.71
P3	60.12
P4	75.93
P5	65.08
P6	73.67
P7	66.26
P8	61.36

6.5.4 Análise dos Resultados

O desempenho do sistema sobre o conjunto de treinamento alcançou uma concordância em torno 87 % com o especialista humano, enquanto para os conjuntos de teste os resultados variaram entre 60 a 78 %. Observou-se que nos conjuntos de teste, o sistema não

conseguiu detectar a fase vigília, pois além de ser um estágio difícil de detectar, os dados do paciente utilizado para o treinamento tinha somente 15 amostras dessa classe. Para o Estágio 2, Estágio $\frac{3}{4}$ e Estágio1/REM o sistema apresentou uma performance alta em quase todos os pacientes testados, comprovando o bom desempenho do sistema.

A análise dos hipnogramas (Figuras 6.12 a 6.15) e dos histogramas (Gráficos 6.1 ao 6.4), mostram a viabilidade do sistema ser utilizado como um estagiador. Com os hipnogramas pode-se observar que o sistema quando erra está oscilando entre classes vizinhas, mostrando que na verdade não existe uma divisão tão rígida entre cada classe utilizada pelos especialistas. Esta informação vem em consonância com as discordâncias entre os próprios especialistas da área. Já com os histogramas pode-se observar que no contexto de uma noite de sono, ou o exame de uma noite, as quantidades de cada fase de sono têm uma distribuição muito semelhante àquela apresentada pelo especialista. A distribuição também está em consonância com os tempos de sono apresentados por um jovem adulto. Estes tempos podem ser verificados na seção 2.4.2.1 sobre o sono normal de um jovem adulto.

Outro fator a ser considerado versa sobre a velocidade que o sistema tem para o treinamento e os testes. O tempo para o treinamento foi aproximadamente de 15 segundos³¹, e o tempo para a realização dos testes ficaram em torno dos 30 segundos, esses tempos são variáveis de acordo com a quantidade de tempo do exame do paciente.

A generalização

O sistema foi treinado e testado com pacientes jovens adultos. Sabe-se que o padrão do sono muda com a idade. Por exemplo, os idosos quase não apresentam o estágio 4 do sono. As crianças têm muito mais REM que os adultos e os registros são muito mais complexos. Então, não seria viável utilizar o sistema treinado com um paciente X para estagiar qualquer paciente. Deve-se levar em consideração a idade do paciente. Poderia se ter vários sistemas treinados com pacientes de faixas etárias distintas, para ser utilizado de acordo com a idade.

Porém, dentro da mesma faixa etária, podem ser encontrados diversos problemas, como:

- Ainda existem problemas na captura dos dados devido, por exemplo, as flutuações de voltagem (Duffy et al.,-);

³¹ O computador utilizado foi um pentium II 300Mhz.

- Os sinais podem diferir muito de um equipamento para outro, dependendo dos filtros e amplificadores internos utilizados (Duffy et al.,-);
- O sinal pode estar danificado devido à má colocação do eletrodo ou porque o paciente se mexeu muito;
- Diferenças no padrão de estagiamento de um especialista para outro;
- Os pacientes com anormalidades distintas ou tomando alguma medicação podem apresentar registros com padrões alterados (Martinez, 1999);
- Diferenças de potencial elétrico de um paciente para outro, ou seja, o técnico deve definir a sensibilidades dos canais para cada paciente (Duffy et al.,-).

Observando a Tabela 6.6 com relação ao paciente P7 nota-se que o percentual de acerto da classe Est3/4 é relativamente baixo. Este fato, pode encontrar uma explicação na Figura 6.16, onde se vê que os sinais do Est3/4 para os pacientes P1 e P7 apresentam padrões relativamente distintos. Por outro lado, os sinais dos pacientes P1 e P2 apresentam padrões semelhantes, donde obteve-se um bom percentual de acerto (Tabela 6.3).

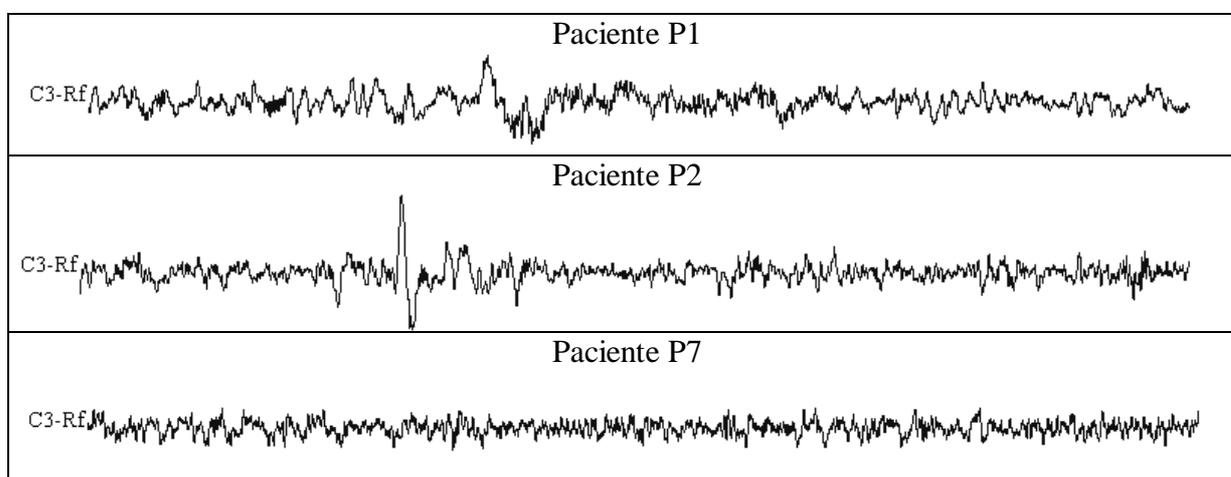


Figura 6.16: Apresenta a semelhança visual dos padrões do Est3/4 para os pacientes P1 (superior) e P2 (central) e a diferença entre os pacientes P1 e P7 (inferior)

A classe Vigília apresenta uma variedade de forma que dificulta o aprendizado do sistema (Figura 6.17). Além disso, quando o paciente está com o olho aberto o sinal de EEG apresenta um padrão diferente de quando com o olho fechado.

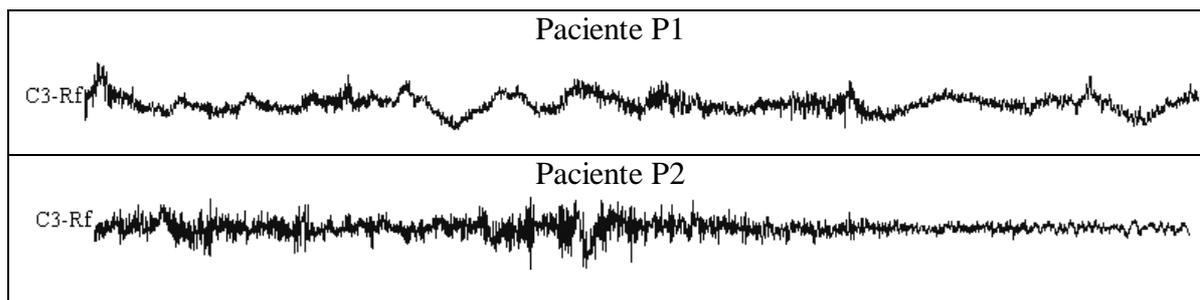


Figura 6.17: Apresenta a variação de padrões da vigília

Esses problemas, que vão desde a coleta dos dados até as diferenças interindivíduos, dificultam a generalização do sistema. Mas isso não impede a utilização do sistema por especialistas, desde que, sejam treinados vários sistemas com padrões de pacientes distintos para serem usados em casos específicos. Caberia ao especialista olhar superficialmente o exame e classificar o padrão do paciente. Cabe lembrar que o treinamento do sistema leva somente 15 segundos.

6.6 Conclusão

O protótipo implementado além de fazer o estagiamento do sono apresenta ao especialista o hipnograma (com o qual ele visualiza o progresso do sono durante a noite), o histograma (que mostra a quantidade de tempo de cada fase do sono).

Os resultados obtidos, treinando o Mapa FAN com os dados de um paciente e testando-o em outros 7 pacientes, foram satisfatórios pois dentro dos limites encontrados por outros pesquisadores. Porém, uma comparação mais rigorosa com outros sistemas não pode ser realizada de modo direto devido às formas distintas utilizadas para a realização do treinamento e dos testes, os dados serem coletados por máquinas distintas, e o estagiamento visual ser feito por especialistas diferentes.

Os resultados encontrados com o Sistema Mapa FAN motivam a continuação das pesquisas e mostram que o problema do estagiamento automático do sono ainda é um desafio para os pesquisadores.

Cabe ressaltar que a generalização do sistema está limitada por várias questões que atualmente fazem parte de pesquisas, como a qualidade dos sinais capturados. Mas isso não impede a sua utilização pelos especialistas desde que sejam levadas em consideração as questões levantadas na Seção 6.5.4.

7

Conclusões e Recomendações

7.1 Conclusões

O sistema desenvolvido nesta tese contribui para o estagiamento automático do sono. Ele, além de realizar o estagiamento do sono, apresenta ao especialista o hipnograma (com o qual ele visualiza o progresso do sono durante a noite) e o histograma (que mostra a quantidade de tempo de cada fase do sono).

Como primeira consideração, pode-se mencionar a rapidez do sistema no estagiamento automático em relação ao visual. O estagiamento automático consome até 1 minuto de tempo máquina, enquanto que o método visual pode consumir em torno de 3 horas. Outro fator relevante é a qualidade do estagiamento, pois o método visual tende a ser cansativo, provocando assim, uma qualidade variável ao longo do estagiamento, enquanto que um sistema automático garante o mesmo desempenho durante todo o processo.

O sistema treinado com os dados de um paciente e testado com outros pacientes, apresentou resultados (entre 60 e 78 %) que foram satisfatórios e estão dentro dos limites encontrados por outros pesquisadores. Porém, uma comparação mais rigorosa com outros sistemas não pode ser realizada de modo direto devido às formas distintas utilizadas para a realização do treinamento e dos testes, os dados serem coletados por máquinas distintas, e o estagiamento visual ser feito por especialistas diferentes.

Cabe ressaltar que a generalização do sistema está limitada por várias questões que atualmente fazem parte de pesquisas, como a qualidade dos sinais capturados. Mas os resultados encontrados com o sistema proposto motivam a continuação das pesquisas e mostram que o sono e o problema do seu estagiamento automático ainda são um desafio para

os pesquisadores. Entretanto, o sistema pode ser utilizado como estagiador automático das fases do sono levando-se em consideração algumas observações, como: a faixa etária do paciente, a forma como o técnico fez a calibragem dos canais (sensibilidade), mesmo equipamento polissonográfico de coleta de registros.

Um novo método de classificação foi apresentado, assim como os resultados obtidos para a classificação automática dos estágios do sono. Durante o estudo observou-se que: a normalização dos dados e a extração de características são passos fundamentais no desempenho do Mapa FAN (assim como o é para outros métodos de classificação); a ordenação do sinal teve um papel fundamental no processo de extração de características; e o pós-processamento com as regras de inferência ajudaram a corrigir algumas falhas do classificador, principalmente nos casos onde o sistema oscilava entre duas classes (geralmente entre o Estágio 2 e o Estágio 1/REM). Este sistema poderá ser utilizado também em outros problemas de classificação de sinais digitais multidimensionais (sinais dispostos no tempo com uma determinada frequência de captura), onde a classificação é realizada por trechos.

Outro fator importante é que, a ordenação (pré-processamento) e o Mapa FAN (classificador) que compõem o modelo, apesar de serem métodos novos, demonstraram resultados comparáveis a outros métodos, o que motiva uma continuação das pesquisas. A ordenação poderá ser utilizada como parte do pré-processamento de sinais digitais para outros classificadores de padrões de sinais digitais amostrados temporalmente, ou seja, dependentes de frequência e tempo de cada amostra.

O trabalho também revela que a utilização de tecnologias de pré-processamento de sinal digital combinadas com sistemas de classificação, demonstra resultados favoráveis a investigações mais profundas. Para o caso do pré-processamento, pode-se ressaltar que a extração de características, merece também estudos mais específicos.

7.2 Recomendações

Para trabalhos futuros, propõe-se: a utilização de múltiplos canais de EEG e de outros canais, como é o caso do eletrooculograma (EOG) e do eletromiograma (EMG) para auxiliar a detecção do estágio REM; e a exploração de outras formas de extração de características para apresentar como entrada para o Mapa FAN. Além disto, treinar os Mapas usando dados de vários pacientes. O desenvolvimento de novas formas de normalização dos dados que

amenizem as variações interpacientes também são necessárias para o melhor desempenho do Mapa FAN, assim como para outros classificadores.

Deve-se levar em consideração a idade do paciente. Poderia se ter vários sistemas treinados com pacientes de faixas etárias distintas, para ser utilizado de acordo com a idade.

Algumas observações, porém, podem ser expostas com este trabalho. A quantidade de amostras para cada fase do sono, é um problema, pois dificulta o treinamento do sistema. Este problema poderia ser sanado com um treinamento com igual quantidade de amostras de cada classe, tomadas de mais de um paciente. Outro problema a ser observado é que existe uma diferença nos sinais de cada paciente devido a diferenças de potenciais na própria coleta, ou mesmo devido a equipamentos diferentes.

Assim, uma generalização, pode ser muito difícil em um contexto maior. Neste sentido uma nova versão do protótipo poderá ser desenvolvida, onde seja feito um semi estagiamento. Este semi estagiamento seria realizado da seguinte forma, o especialista faria o estagiamento de alguns trechos do exame e o sistema com base nestes seria treinado e estagiaria o restante do exame.

Um trabalho futuro, a ser pesquisado, seria a criação de uma classe extra para os ruídos (artefatos).

O sistema apresentado neste trabalho pode ser utilizado para o reconhecimento de palavras faladas com poucas alterações, como o tamanho da amostra e as técnicas utilizadas no pré-processamento (antes da ordenação).

Bibliografia

1. ACKENHUSEN, John G. Signal Processing Technology and Applications. IEEE technology update series, 1995.
2. ASERINK, E. e KLEITMAN, N. Regular periods of eye mobility and concomitant phenomena during sleep. Science, n. 118, 1953.
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. 36, p. 194-210, 1997.
4. 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.
5. BELLMAN, R. Adaptive Control Processes: A Guided Tour. Princeton University Press, 1961.
6. BERTHOMER, C., PRADO, J. e BENOIT, O. EEG Analysis Using Non-Uniform Oversampled Filter Banks. Biomedical Sciences Instrumentation, v. 34, p. 119-124, 1997.
7. BIANCO, Margarida. Classificação dos distúrbios do sono. In : REIMÃO, Rubens. Sono : Estudo Abrangente. 2. Ed. São Paulo: Atheneu, 1996.
8. BRACEWELL, R. The Fourier Transform and its Applications. New York: McGraw-Hill, 1965.
9. BRIGHAM, E.O. The fast Fourier Transform. Prentice Hall. New Jersey: 1974.
10. BURGER, D. CANTANI, P e WEST, J. Multidimensional Analysis of Sleep Electrophysiological Signal. Biology Cybernetics. V. 26, p. 131-139, 1977.
11. CARREIRA-PERPIÑÁN, M. Á. A Review of Dimension Reduction Techniques, Technical Report CS-96-09, 1997. <http://www.dcs.shef.ac.uk/~miguel/papers/cs-96-09.ps.gz> (27 de Maio de 1998, 01:30).
12. 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.
13. 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.
14. COLOMBO, C., BIMBO, A. D. Color-Induced Image Representation and Retrieval. Pattern Recognition, v. 32, p. 1685-1695, 1999.

15. COOLEY, J. W.; TUKEY, J. W. An Algorithm for the Machine Calculation of Complex Fourier Series. Math of Computation, vol. 19, pp. 297-301, 1965.
16. DANDOLINI, Gertrudes A. Um procedimento para avaliação da saúde financeira de pequenas empresas: estudo de um caso usando redes neuronais artificiais. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Departamento de Engenharia de Produção, 1996.
17. DAUBECHIES, I. Where do Wavelets Come From? -- A Personal Point of View. Proc. of IEEE, vol. 84, no. 4, 1996.
18. De KONINCK, J; LORRAIN, D; CHRIST, G; PROULX, G; COULOMBE, D: Intensive language and increases in rapid eye movement sleep: evidence of a performance factor. Int. J. Psychophysiol, 8:43-47, 1989.
19. DEGROOT, Jack. Neuroanatomia. ed. 21. Rio de Janeiro: Guanabara, 1994.
20. DOVICCHI, J. C. L. Novos Coeficientes Wavelets Baseados em Intervalos Musicais para Análise Timbres de Instrumentos Acústicos. Tese. Pós-Graduação Em Engenharia Elétrica Universidade Federal de Uberlândia, Outubro, 1999.
21. DUDA, O., HART, P. E. Pattern classification and scene analysis. John Wiley & Sons, Inc., 1973.
22. DUFFY, F. H., IYER, V. G., SURWILLO, W. W. Eletroencefalografia Clínica e Mapeamento Cerebral Topográfico. Springer-Verlag, -.
23. EMSA – Equipamentos Médicos S/A. EMSA. 1998. <http://www.emsamed.com.br> (15 de Março de 2000).
24. EPSTEIN, I. Teoria da Informação. Segunda Edição. Editora Ática. São Paulo, 1988.
25. FARIA, Regis Rossi A. Wavelets e as artes multiresolucionárias. 1997 Wavelets at LSI.htm, --
26. FISHER, R., PERKINS, S., WALKER, A., WOLFART, E. Hypermedia Image Processing Reference. England: John Wiley & Sons Ltd, 1996.
27. GOMES, J. e Velho, L. Computação Gráfica: Imagem. Rio de Janeiro, IMPA/SBM, 1994, 424 p.
28. GRAPS, A. An Introduction to Wavelets. IEEE Computational Science and Engineering, vol. 2, no 2, Summer 95, 1995.
29. GREEN, David Alan. A Hybrid Preprocessor for Sleep Staging Using the EEG. Ottawa. Dissertação (M.Eng.). Department of Systems and Computer Engineering, CARLETON University, 1975.
30. GUIOT, Marilene. Polissonografia. In : REIMÃO, Rubens. Sono : Estudo Abrangente. 2. Ed. São Paulo : Atheneu, 1996.
31. GUYTON, Arthur. Neurociências Básica. 2. Ed. .Rio de Janeiro : Guanabara, 1993.
32. HADJIYANNKIS, K. et al. 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.

33. HAYKIN, Simon. Neural Networks: A comprehensive Foundation. New York: Macmillan College Publish Company, 1994.
34. IFEACHOR, E. C. e JERVIS, B. W. Digital Signal Processing – A Practical Approach. Addison-Wesley, 1995.
35. JOHNSON, R. A., WICHERN, D. W. Applied Multivariate Statistical Analysis. New Jersey: Prentice Hall inc., 4 ed., 1998.
36. JOUVET, M. 1977. O sonho - Textos selecionados de La Recherche. Seuil: Paris, 125-164.
37. JUDEX SYSTEMS. <http://www.judex.dk> (09 de Setembro de 1998).
38. KARACAN, I. e SHAPIRO, A. Erection cycle during sleep in relation to dream anxiety. Archive Genital Psychiatric, n. 15, 1966.
39. KLEITMAN, D. Padrões de Sonhos. In: Scientific American (ed) Psicobiologia, EDUSP - Polígono: São Paulo, cap. 29:241-249, 1973.
40. KLIR, G. e YUAN, B. Fuzzy sets and fuzzy logics - Theory and Applications, Prentice Hall, PTR, 1995.
41. KUC, R. Introduction to Digital Signal Processing, McGraw Hill Book Co., New York, 474 pp., 1982.
42. 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).
43. 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.
44. LOOMIS, A. L., HARVEY, E.N., HOBART, G. Further observations on potencial rhythms of the cerebral cortex during sleep. Science 82:198-200, 1935.
45. LOSSMANN, Erik . EEG-based sleep stage scoring using wavelet transform and artificial neural network. In : Proceedings of the post-graduate student seminar. Anais, Tallinn Technical University, 1996.
46. LOSSMANN, Erik. Computerized Sleep Stage Scoring. 1997. <http://crnet4.carelian.fi/euromed/sss/sss.html> (09 de Setembro de 1998).
47. MADISSETTI, Vijay K. Signal Processing for the NII - Workshop/Panel Report. <http://users.ece.gatech.edu/~vkm/nii/> (04 de abril de 2000, 02:00).
48. MALCON, A. Tafner, Estagiamento Automático do Sono Utilizando um Canal de EEG e uma Rede Neural Artificial com Alta Representação Cortical, Florianópolis, 1999, Tese (Doutorado em Engenharia de Produção), Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina.
49. MARANHÃO, R. M. G. Uma Proposta de Comunicação para Uso de Organizações que Atuem em Áreas Inóspitas da Região Amazônica. Dissertação. Programa de Pós-Graduação em Ciências da Computação. Universidade Federal de Santa Catarina. Florianópolis, 1999.
50. MARTINEZ, D. Prática da Medicina do Sono. São Paulo: BYK, 1999.

51. MEDICAL Knowledge Based Systems. 1996. http://www.vision.auc.dk/Forskning_eval/Chapter_4_final.html (09 de Setembro de 1998).
52. MENDES, C. C. L., Fonseca, E. V., Pontes, F. R., Moura, P. S., Andrade, R. D., Simões, R. ALVES, R. P. e Guimarães, R. M. Panorama do sono e dos sonhos, da infância à velhice há cuidados e características. Monografia. <http://www.icb.ufmg.br/lpf/revista/monografia6/> (14 de julho de 1999. 16:2)
53. MOLES, A. Teoria da Informação e percepção estética. Rio de Janeiro. Tempo Brasileira, 1969. (Livro considerado clássico no tema. Traduzido para várias línguas.)
54. MOTA, C., FERREIRA, H. e ROSA, A. Independent and Simultaneous Evolution of Fuzzy Sleep Classifiers by Genetic Algorithms, Gecco 99, Orlando, July 1999.
55. NIEDERMEYER e SILVA F.L. DA Electroencephalography Basic Principles, Clinical Applications, and Related Fields. 3ª Edição, Willians e Wilkins, 1993.
56. 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.
57. OPPENHEIM, A. V. e SCHAFER, R. W. Digital Signal Processing. Prentice-Hall, 1975.
58. OROPESA, E., CYCON, H. L., e JOBERT, M. Sleep Stage Classification using Wavelet Transform and Neural Network. <ftp://ftp.icsi.berkeley.edu/pub/techreports/1999/tr-99-008.ps.gz> (13 de março de 2000).
59. PANDYA, A., MACY, R.B. Pattern Recognition with Neural Networks in C++. CRC Press, 1995.
60. PERRIER, V.; PHILIPPOVITCH, T. e BASDEVANT, C. Wavelet Spectra Compared to Fourier Spectra. Tech. Rep., Lab. de Météorologie Dynamique, Paris, --.
61. PIMENTEL-SOUZA, F. Cidadão de segunda classe. Jornal Estado de Minas, BH, 9 maio, 1990.
62. PIMENTEL-SOUZA, F. Dormir (bem) é precioso. Entrevista para o Jornal Estado de Minas, BH, 10 fevereiro, 1991.
63. 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).
64. 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.
65. 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.
66. RABINER, L. R., GOLD, B. Theory and Application of Digital Signal Processing. Prentice-Hall, 1975.
67. RAITTZ, R. T., SOUZA, J. A. DANDOLINI, G. A., et al. Pré-Processamento de Sinais Digitais. XIX ENEGEP - Encontro Nacional de Engenharia de Produção, 1999.

68. RAITTZ, R. T., SOUZA, J. A. DANDOLINI, G. A., et al., FAN: Learning by Means of Free Associative Neurons, WCCI98 - IEEE World Congress on Computational Intelligence, Anchorage Alaska, pp. 425-430, May 1998.
69. RAITTZ, R. T.; SOUZA, J.A.; DANDOLINI, G. A.; PACHECO, R. C. S.; MARTINS, A., GAUTHIER, F & BARCIA, R.. Learning by Means of Free Associative Neurons. NAFIPS 97: Annual Meeting Of The North American Fuzzy Information Processing Society, September 21-24, 1997, Syracuse, New York.
70. 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.
71. RECHTSCHAFFEN A, KALES A. (Eds) A Manual of Standardised Terminology and Scoring System for Sleep Stages of Human Sleep. Brain Information Service/Brain Research Institute, 1968, University of California at Los Angeles
72. REIMÃO, R. Sono: estudo abrangente. Atheneu: São Paulo, 1996.
73. RESTIVO, F. J. O. Processamento Digital de Sinal. Faculdade de Engenharia da Universidade do Porto, Dez/1998. ftp://ftp.fe.up.pt/pub/Pessoal/Deec/fjr/pds/PDS_9899.pdf (25 de novembro de 1999, 23:27).
74. ROBINSON, E. in Signal Processing Society Monographs. <http://www.ieee.org/organizations/society/sp/mongrphs.html> (04 de abril de 2000, 01:36).
75. ROSA, A.C., PARRINO, L. e TERZANO, M.G. Automatic Detection of Cyclic Alternating Pattern (CAP) Sequences in sleep: Preliminary results. <http://laseeb2.isr.ist.utl.pt/publications/papers/acrosa/caps-p10r3r2f.htm> (15 de janeiro de 2000)
76. ROSS, Timoty J. Fuzzy Logic with Engineering Applications. McGraw-Hill inc., 1995.
77. SABBATINI, R. M. E. Mapeando o Cérebro. Revista Cérebro & Mente, Agosto/Setembro 1997.
78. SABBATINI, Renato M.E. O Computador no Processamento de Sinais Biológicos. Revista Infomédica, 2 (12): 5-9, 1995.
79. SCHALTENBRAND, N. et al. Sleep Scoring Using the Neural Network Model: Comparison Between Visual and Automatic Analysis in Normal Subjects and Patients. Journal Sleep, v. 19, 1995.
80. SCHAUFF, Charles, MOFFET, David, MOFFET, Stacia. Fisiologia Humana. Rio de Janeiro: Guanabara, 1993.
81. SCHOWENGERDT, Robert A. Remote Sensing – Models and Methods for Image Processing. Segunda Edição, Academic Press, pp. 522, 1997.
82. SHANNON, C.; WEAVER, W. A. Teoria Matemática da Comunicação. Rio de Janeiro, Difel, 1975.
83. 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).

84. SMITH, Steven W. *The Scientist and Engineer's Guide to Digital Signal Processing*, California Technical Publishing, 1998.
85. SOUZA, João Artur. Reconhecimento de Padrões Usando Indexação Recursiva. Florianópolis, 1999. Tese (Doutorado em Engenharia de Produção). Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina.
86. 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.
87. 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.
88. TANKOVA, Iren e BUELA-CASAL, Gualberto. Sono e envelhecimento. In : REIMÃO, Rubens. Sono : Estudo Abrangente. 2. Ed. São Paulo : Atheneu, 1996.
89. TEITENBAUM. Sono e Vigília. In - Psicologia Fisiológica, Zahar: Rio de Janeiro, 104-117, 1969.
90. TOMPKINS, W. J. (Editor) Biomedical Digital Signal Processing. Prentice Hall, 1995.
91. WWW_01, <http://narcisus.esd.ece.ntua.gr/~www/euromed.html> (17 de dezembro de 1999, 00:31).
92. WWW_02, Fourier and the Frequency Domain. <http://www.spd.eee.strath.ac.uk/~interact/FFT/fourier.html> (20 de abril de 2000, 01:13).
93. WWW_03, Introduction to Digital Filters. <http://www.barbush.demon.co.uk/dsp/digfilt.pdf> (13 de junho de 1999, 18:06).
94. ZADEH, L.A. Fuzzy sets. Information and Control, Vol. 8, 1965, pp. 338-353.