

## Sistema Integrado para Análise e Classificação Automática do Electroencefalograma do Sono

Oswaldo Pacheco, Francisco Vaz

**Resumo** - Neste artigo apresentamos um sistema integrado de análise e classificação automática do EEG de sono. Nas metodologias adoptadas, podem-se identificar três partes distintas. A primeira consiste na identificação dos padrões elementares no EEG (actividade delta, alfa, fusos de sono e complexos K) e no EOG e na caracterização do EMG. A segunda parte, consiste na classificação dos parâmetros obtidos, usando uma rede neuronal multicamada *feedforward*. Numa terceira fase, uma segunda rede neuronal, é usada para supervisionar os resultados automáticos produzidos pela primeira rede. Neste trabalho, apresentamos também, os métodos desenvolvidos, para a detecção de micro despertares. O desempenho do sistema foi avaliado usando 20 horas de dados recolhidos de 8 pacientes. Regista-se elevada concordância global, entre os resultados produzidos pelo sistema e a avaliação realizada pelos especialistas.

**Abstract** - In this paper we describe a system for automatic all night analysis of sleep, based on neural networks. The system consists of a three step analysis. The first step is the recognition of elementary patterns in EEG (delta, alpha, spindle and K complex waves), EOG and EMG, and spectral analysis for background activity. The second step is the determination of sleep stages based on these parameters. Automatic sleep scoring was performed using a multilayer feedforward network. The last step, is the supervision of the automatic decision using ambiguity rejection and coherence analysis. This work presents also, an automated system for micro arousals detection based on k-means method. The system was validated with a data set including 8 recordings (20 h). Overall agreement between the computer and human judges indicates considerable reliability of the system.

### I. INTRODUÇÃO

Nas sociedades mais evoluídas, de dia para dia, maior é o número de pacientes que sofrem de patologias ligadas ao sono, pelo que, têm surgido em todo o mundo, inúmeros laboratórios e clínicas de análise de sono. A análise de um registo, é para o especialista, um trabalho difícil e cansativo, devido à dificuldade existente em manusear um conjunto significativo de variáveis durante um período de tempo considerável. Vários sistemas automáticos foram desenvolvidos, com o objectivo de minorar os problemas levantados [1,2,3,4]. Apesar disso, algumas questões permanecem em aberto [5]. Primeiro, a distinção dos

estádios de sono mais superficiais não é muito eficaz. Segundo, os sistemas descritos não apresentam qualquer indicador da qualidade da classificação, não permitindo por parte do especialista, uma reavaliação qualitativa, na procura da diminuição dos erros produzidos. Finalmente, os sistemas automáticos de classificação de épocas de EEG em estádios de sono, baseiam-se, na perspectiva clássica de Rechtschaffen e Kales (R&K) [6], sendo a época analisada como um todo, não se atendendo às micro transições que eventualmente ocorrem no intervalo de tempo que se pretende caracterizar. Por isso, para alguns tipos de patologias, a análise clássica, de *per se* não caracteriza completamente o sono, uma vez que para alguns pacientes, o sono é fragmentado por aumentos transitórios da vigília, que em muitos casos não conduzem à passagem ao estado de acordado, e que, portanto, não podem ser detectadas por simples observação do hipnograma. O hipnograma pode neste caso, não reflectir qualquer desvio relativamente ao que se obtém a partir de padrões normais, apesar da má qualidade do sono do paciente. Torna-se assim necessário, no estudo de algumas doenças de sono, a análise em duas escalas diferentes: o estudo clássico do comportamento do sono, com base na classificação de segmentos de comprimento temporal fixo; e a detecção de estados transitórios que ocorram num qualquer momento, nomeadamente, a detecção de aumentos da vigília, durante curtos instantes.

A resolução dos problemas enunciados, constituiu a motivação principal que presidiu a este trabalho [7]. Assim, neste artigo, apresentamos um sistema automático de análise e classificação do EEG de sono em tempo real, que permite a detecção de transitórios aos estádios definidos pelo paradigma de R&K, nomeadamente os micro despertares, melhorando também, os resultados da classificação quando é necessário distinguir os estádios de sono mais superficiais. Este sistema, fornece uma avaliação automática da classificação realizada, com base na análise da consistência dos vectores dos parâmetros característicos, e da análise da coerência das saídas, indicando qual o grau de credibilidade da saída produzida.

### II. MÉTODOS

As metodologias desenvolvidas vão ser apresentadas em 3 partes distintas. Assim na parte A, expomos os métodos, usados para a classificação automática de segmentos de EEG em estádios de sono. O modelo de

classificação, baseado em redes neuronais, é um dispositivo treinado com base em exemplos, pelo que é sempre possível, que se produzam estimativas incorrectas, nomeadamente, quando a rede opera numa região do espaço de entrada em que não foi treinada. A utilidade de um classificador modelado da forma descrita, pode assim ser bem maior, se fornecer também um indicador de confiança para a estimativa apresentada. Assim, uma segunda rede é usada para supervisionar a classificação obtida. Na prática esta segunda rede, produz uma saída adicional, que indica se o classificador está a extrapolar, isto é, através desta saída é possível saber se a rede está ou não a ser utilizada numa região do espaço de entradas onde foi treinada. Apresenta-se ainda um método, que partindo da análise das saídas da rede de classificação, permite a rejeição de alguns dos resultados, devido à sua ambiguidade. Os mecanismos de supervisão são apresentados na parte B. Finalmente, na parte C, vamos expor os métodos desenvolvidos que permitem a detecção automática dos micro despertares.

#### A. Classificação de segmentos de EEG em estádios de sono

Os métodos implementados, baseiam-se na análise em simultâneo de 5 sinais: EEG (três canais - frontal, central e occipital), EMG e EOG. O processamento (à excepção do módulo de contexto) é realizado em tempo real e podem-se distinguir três partes distintas:

- Extracção de parâmetros característicos, usando técnicas de processamento de sinal;
- Classificação em estádios de sono, do vector de parâmetros produzido para cada segmento de 30 segundos;
- Distinção dos estádios 1/REM e 3/4, e refinamento da classificação, usando um conjunto de regras de contexto, que incorporam o conhecimento do especialista;

##### A.1. Extracção de parâmetros

A digitalização de todos os canais é feita a 200 Hz, com 12 bits de precisão. Para cada tipo de actividade é configurado um detector. O condicionamento e a parameterização do sinal, é diferente de detector para detector. Após a filtragem, que permite a diminuição do efeito das componentes de frequência indesejadas, a diminuição da influência do ruído de alta frequência e dos artefactos de baixa frequência, são detectados todos os picos e passagens por zero dos sinais. Os parâmetros obtidos, são depois convertidos numa sequência de 3 valores: 0, 1/2, 1. Tomará o valor 0 se a amplitude pico a pico da onda em estudo não ultrapassar o limiar para a actividade em estudo ou se o período não pertencer ao intervalo característico. Tomará o valor 1/2 se a amplitude for superior ao limiar e o período pertencer à fronteira do intervalo estabelecido e valerá 1 se pertencer ao intervalo e a amplitude for superior ao referido limiar.

A sequência destes valores constitui a entrada de um somador, que se anula sempre que um zero é encontrado. Quando o somador atinge o valor mínimo considerado para a actividade em estudo, a soma dos períodos das ondas consecutivas que obedecem aos critérios estabelecidos, correspondem ao tempo mínimo de duração de uma dada actividade. Considera-se que a actividade terminou quando para conjuntos de 6 ondas, se encontram 3 que não cumprem os critérios definidos.

Após cada detecção, e para um segmento de 10 segundos, um conjunto de regras de contexto são aplicadas, com o objectivo de eliminar falsos positivos. Para a actividade delta, detectada no canal frontal, verifica-se da existência em simultâneo de movimentos oculares. Se ocorrer em simultâneo uma onda lenta, de amplitude superior a 100  $\mu$ V, o evento não é considerado. Por outro lado, para a mesma actividade, verifica-se igualmente se nos três canais de EEG, existem ondas semelhantes, com inicio na mesma referência temporal. A semelhança é medida através do cálculo do declive da primeira rampa. Caso a resposta seja afirmativa, o evento é assinalado, mas não contabilizado para o processamento posterior, porque é elevada a probabilidade que a deflexão simultânea nos três canais, seja devida a um artefacto. Para a actividade alfa, testa-se na sua vizinhança (5 segundos) a ocorrência de um fuso de sono. Se este for registado, a menos que também ocorra um complexo K, que pode ser indiciador da ocorrência de um despertar, a actividade é assinalada, mas não é contabilizada para a classificação.

Um dos principais problemas, dos sistemas apresentados para classificação automática de EEG de sono, tem a ver com a dificuldade de distinguir os estádios de sono mais ligeiros. Esta dificuldade, prende-se com o facto de existirem segmentos classificados como W, 1 ou mesmo 2, que não registam qualquer dos eventos descritos, pelo que se torna importante, que o sistema integre, para além dos descritores baseados em métodos do domínio do tempo, métodos que quantifiquem as características espectrais dos sinais.

O cálculo dos parâmetros de Hjorth [8] para um curto segmento de sinal, permite a quantificação das suas características genéricas, sendo possível derivar as propriedades básicas do espectro, sem recorrer à análise em frequência, diminuindo-se assim a complexidade computacional.

A caracterização da actividade de base, é obtida determinando-se a importância relativa de cada banda com interesse clínico. Optamos, por calcular os dois primeiros parâmetros propostos por Hjorth, para as versões filtradas dos sinais originais, que constituem as entradas dos detectores de eventos característicos, apresentados anteriormente. Com esta aproximação, para cada versão filtrada do sinal, é calculada a variância da amplitude e estimada a frequência média, o que permite por comparação entre os resultados obtidos para as diferentes bandas, determinar para cada segmento a importância relativa de cada banda.

Heuristicamente, desenvolveram-se para cada banda em análise, funções de duas entradas (actividade e mobilidade), cuja saída é o coeficiente de relevância de banda, indicador da importância dessa banda no segmento em análise (figura 1).

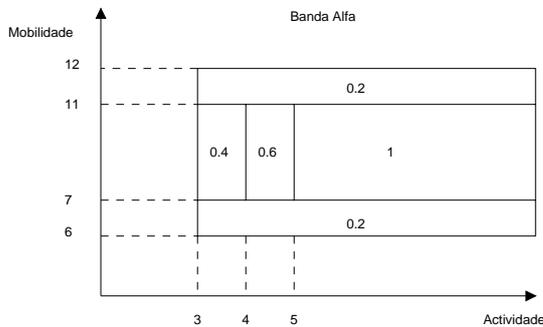


Figura 1. Função que permite o cálculo do coeficiente de relevância de banda, para a banda alfa.

A partir da actividade e da mobilidade calculada para as quatro versões filtradas do sinal, foi estabelecido um quinto parâmetro, que determina quais os segmentos que podem ser considerados de baixa amplitude e de frequência variada (segmentos LVMF), características que estão associadas ao dessincronismo do EEG, típico do estágio 1. Para a determinação deste parâmetro basta verificar, para limiares relativos, se em nenhum dos estudos, o coeficiente de relevância atingiu 0.4, e se amplitude média pode ser classificada de baixa (menor que 10  $\mu$ V).

Os coeficientes de relevância de banda, são calculados para segmentos de 1 segundo. Para cada 30 segundos, são calculadas as suas médias.

A partir do EOG, detectam-se os eventos REM (*Rapid Eye Movements*). Estes eventos podem ocorrer isoladamente ou em complexo, mas a análise é feita onda a onda. O detector corresponde também, à junção de um filtro especificado para este tipo de actividade (0.5-7 Hz), com um discriminador de amplitude e de período, ao que se junta o cálculo dos declives, e um módulo de reconhecimento do padrão, que actua por comparação com um conjunto de níveis previamente definidos. O cálculo do declive permite estudar a morfologia do sinal, e recuperar algumas falsas detecções, pois sabe-se que os REM são caracterizados, por uma rápida transição inicial. Para este detector específico, o discriminador não actua sobre o zero, mas sim com base num limiar positivo e negativo (mais ou menos 20  $\mu$ V). O critério por nós usado para o detector de eventos REM, consiste em considerar as ondas que apresentam variações de amplitude entre 20 e 250  $\mu$ V e de duração entre 20 a 110 msec. Foi também imposto, para as ondas de arcada positiva, que o declive ascendente (da linha que une a primeira passagem por zero e o pico), seja superior ao declive descendente (da linha que une o pico com a segunda passagem por zero). O inverso foi considerado, para as ondas de arcada negativa.

A amplitude do EMG durante a ocorrência de um artefacto, sofre variações muito apreciáveis ao longo do tempo, que são facilmente caracterizadas pela potência do sinal. Um método de estimação da potência de um dado sinal, consiste, em aplicar uma não linearidade ( $(\cdot)^2$ ) seguida de um filtro passa baixo. Para cada 8 segundos de sinal é calculada a média dos valores obtidos para cada segmento de meio segundo. No nível seguinte, para cada novo segmento, é calculado o quociente entre valor obtido e a média anterior, sendo a média de 8 segundos actualizada ao longo do tempo. Um simples teste de limiar (2.0) aplicado ao quociente permite a detecção dos artefactos musculares. O fim do artefacto é considerado, quando a estimativa de potência tomar 1.5 do valor anterior ao artefacto.

## A.2. Classificação de segmentos de EEG em estádios de sono

A classificação do vector de parâmetros característicos é feito através de uma rede neuronal. A opção por este classificador, deveu-se à simplicidade da implementação, aliada aos bons resultados obtidos [3].

No classificador que vamos apresentar, distinguem-se três níveis distintos: o primeiro, consiste na normalização do vector de entrada da rede; o segundo é constituído pela rede neuronal de classificação e finalmente no terceiro realizamos o refinamento da classificação usando a informação de contexto.

### A.2.1. Normalização do vector de entrada

A classificação das épocas de sinal em estádios de sono, é feita com base no paradigma de R&K, pelo que as entradas do sistema devem ser constituídas por informação percentual das actividades presentes na época.

A informação (parâmetros) que optamos por fornecer à rede é constituída pelas actividades do EEG (delta, alfa, fusos de sono e complexos K) e pelos três parâmetros, indicadores da relevância da banda alfa e da banda beta e da duração dos segmentos dominados por EEG de baixa amplitude e de frequência variada (LVMF), derivados dos parâmetros de Hjorth. Temos assim, para cada época de 30 segundos, um vector de sete elementos.

Para se obter alguma normalização à entrada da rede, atribuímos níveis de codificação a cada elemento do vector, tentando identificar a relevância para a classificação de R&K contida nos valores iniciais. Optamos assim por codificar os parâmetros em quatro níveis: {0,1,2,3} a que correspondem os adjetivos elevado, médio, baixo e irrelevante. Com esta normalização, para além de se apresentar à entrada da rede, valores sempre compreendidos entre 0 e 3, também se reduz o eventual efeito negativo, associado ao facto dos parâmetros serem medidos ou detectados em diferentes unidades.

### A.2.2. Classificação de segmentos de sinal em estádios de sono através de uma rede neuronal

O vector normalizado da forma apresentada anteriormente, constitui a entrada da rede, pretendendo-se que o modelo apresente na sua saída o estádio de sono correspondente. Para a sintetização do modelo, foi necessário seleccionar uma topologia para a rede, um conjunto de dados previamente classificados para o treino, que garantam uma boa generalização, e escolher um método para realizar a aprendizagem. No desenvolvimento deste processo, é importante dispor de um simulador, que permita o treino e o teste de uma rede, para as diferentes versões em estudo. Neste trabalho, foi usado um simulador (*NeuroSim*) desenvolvido pelo grupo que o autor integra [9], realizado com base numa linguagem interpretada NSL (*Neuro-simulation language*). Este simulador, permite o treino de uma rede (qualquer que seja a sua topologia), usando algoritmo de aprendizagem *backpropagation* [10], bem como o teste ao seu funcionamento em qualquer fase do treino. O conjunto de treino é constituído por 640 elementos e o de validação tem 1200 vectores. A rede que produziu melhores resultados, é uma rede *feedforward*, com três camadas e que possui 10 unidades de processamento *hidden* e 4 unidades de saída.

Optamos por treinar a rede de forma a que a saída tenha codificado 0, 1, 2 ou 3, (apenas 4 dos 6 estádios) pois com os vectores que são apresentados, não é possível distinguir o estádio 1 e REM (é necessário a informação recolhida do EMG e do REM), sendo a distinção dos estádios 3 e 4 feita facilmente *a posteriori*, através da análise da percentagem de actividade delta existente na época. Assim, à saída da rede, existe um módulo, que implementa um conjunto de regras e que tem por entrada a classe atribuída ao vector de parâmetros, a classificação do trecho anterior, o número de REM's que ocorreram neste segmento, a estimativa da potência do EMG da época em análise e da anterior e a percentagem de actividade delta existente na época, e por saída um dos 5 estádios previstos.

### A.2.3. Classificação por contexto

O passo seguinte, consiste em fazer uma análise global à classificação produzida pelos níveis anteriores. Como, neste nível é usada a informação das épocas seguintes à época em análise, o processamento é feito em tempo diferido. Com este módulo pretende-se "suavizar" as transições e recuperar alguns erros, usando a informação de contexto.

A partir do início do ficheiro, que contém a classe atribuída a cada uma das épocas, o índice de crédito atribuído a cada classificação e a indicação se a rede extrapolou, verifica-se a existência de épocas REM, até ao aparecimento de uma sequência de épocas classificadas em estádio 2. Estas épocas no início dos exames deveriam ser classificadas no estádio 0, no entanto, quando não

ocorre actividade alfa, a rede pode classificar os trechos em estádio 1, e as regras de contexto atendendo à existência de REM's atribui incorrectamente à época o estádio REM. A solução passa por neste módulo, ignorarmos a actividade REM até ao aparecimento de uma sequência de épocas classificadas em estádio 2. Um segundo conjunto de regras de classificação de contexto, procura recuperar algumas falsas transições de REM para o estádio 1. Nesta segunda passagem pelo ficheiro de classificação, procura-se detectar o início e o fim de uma sequência de sono REM, procurando-se recuperar as classificações incorrectas que ocorram no meio da sequência. O módulo de classificação usando a informação de contexto, faz ainda uma terceira passagem, sobre o ficheiro, onde são registadas as classificações de um dado exame. Nesta terceira passagem, procura-se igualmente incorporar o conhecimento usado pelo especialista. Na tabela 1, apresentam-se as transições de estádio possíveis, que o especialista têm em conta durante a classificação.

| Estádio anterior | Novo estádio        |
|------------------|---------------------|
| 0                | {0, 1, 2}           |
| 1                | {1, 0, 2, REM}      |
| 2                | {2, 0, 1, 3/4, REM} |
| 3/4              | {3/4, 2, 0, REM}    |
| REM              | {REM, 0, 1, 2}      |

Tabela 1. Transições de estádio que podem ocorrer durante o sono.

Analisando a tabela anterior, verifica-se que do estádio 2, qualquer transição pode ocorrer, no entanto, dos restantes estádios existem transições que não são permitidas. Quando do sistema automático resultam transições deste tipo, este módulo atribui novas classes, de acordo com a tabela 2.

| Estádio anterior | Novo estádio | Estádio corrigido |
|------------------|--------------|-------------------|
| 0                | 3/4          | 2                 |
| 0                | REM          | 1                 |
| 1                | 3/4          | 2                 |
| 3/4              | 1            | 2                 |
| REM              | 3/4          | 2                 |

Tabela 2. Correções efectuadas para as transições de estádio não permitidas.

Finalmente, em sequências de épocas classificadas como estádio 2, interrompidas por uma época isolada, classificada como estádio 1, esta é corrigida para estádio 2. Este critério, também é usado pelos especialistas, pois o paradigma de R&K, considera que podem existir varias épocas estádio 2, sem a presença de actividade que as identifiquem.

## A.3. Supervisão da classificação

### A.3.1. Estimativa da densidade de dados de treino

O modelo de classificação, baseado em redes neuronais, é um dispositivo treinado com base em exemplos, pelo

que é sempre possível, que se produzam estimativas incorrectas, nomeadamente, quando a rede opera numa região do espaço de entrada em que não foi treinada. A utilidade de um classificador modelado da forma descrita, pode assim ser bem maior, se fornecer também um indicador de confiança para a estimativa apresentada.

O modelo que propomos para supervisionar a classificação de épocas de EEG em estádios de sono, foi sugerido por Leonard [11], e permite obter uma medida do grau de confiança dum modelo formalizado, através de uma rede neuronal. A detecção de extrapolação proposta por Leonard, baseia-se numa estimativa da densidade de dados de treino. Considera-se que o modelo está a extrapolar quando a densidade de dados é inferior a um determinado limiar previamente definido, significando que nestas circunstâncias, a rede opera em regiões em que não estavam disponíveis dados de treino, ou se existiam, estes eram escassos.

Assim, uma segunda rede é usada para supervisionar a classificação obtida. Na prática esta segunda rede, produz uma saída adicional, que indica se o classificador está a extrapolar, isto é, através desta saída é possível saber se a rede está ou não a ser utilizada numa região do espaço de entradas onde foi treinada.

A rede de supervisão foi treinada a partir de um conjunto de 1820 vectores. Os 640 elementos de treino da rede de classificação, têm a saída a 1 (significando que é dado de treino) e os restantes têm a saída a 0. O segundo conjunto, compreende dados correspondentes a transições de estádios (com características comuns a dois estádios), segmentos com artefactos (falsos positivos delta e actividades de frequência mais alta) e vectores "impossíveis". A rede de supervisão, possui 15 unidades de processamento *hidden* e uma unidade de saída.

### A.3.2. Estudo da coerência das saídas

O segundo método de supervisão, assenta na análise das saídas da rede. Atendendo, como se demonstra [12], que uma rede neuronal multicamada, treinada com base num critério de minimização do erro quadrático médio, com o número de saídas igual ao número de classes, em que se pretende que uma tome o valor um e as restantes o valor zero, adapta os pesos aproximando a rede a um classificador de mínima probabilidade de erro, pode acontecer que a saída do classificador apresente, para um dado vector de entrada, valores elevados para mais do que uma saída. Um bom exemplo para esta situação, ocorre para uma época, que encerre a transição de estádio, em que os parâmetros obtidos para os primeiros 15 segundos indiciam uma época, e os parâmetros obtidos para o restante tempo, correspondem a outra. Perante este cenário, é grande a probabilidade da rede atribuir saídas elevadas para dois diferentes estádios. Na busca de uma solução para este problema, propomos um critério, para determinar, quando a entrada da rede pertence a uma zona ambígua do espaço de entradas.

Considerando assim, que a rede tem  $n$  saídas e que a entrada pertencerá à classe  $i$  se a componente  $i$  do vector de saída for igual a um e as restantes igual a zero, o vector de saída obtido é um valor contínuo que pertence ao hiper-cubo  $[0,1]^n$ . Para todas as saídas calculamos a distância euclidiana entre o valor obtido e o teórico correspondente. O critério usado para a atribuição do índice (alto, baixo) de credibilidade à classificação produzida pela rede, consiste em considerar baixa a credibilidade, se a distâncias euclidiana obtida entre o vector de saída produzida pela rede e o vector correspondente aos valores teóricos, for inferior a um determinado limiar definido heurísticamente.

### C. Detecção de micro despertares

Os micro despertares podem-se definir como transitórios, dos quais normalmente não resulta a passagem à vigília, podendo ser identificados nos registos poligráficos clássicos, sendo caracterizados por mudanças abruptas na frequência do EEG (sugerindo o estádio acordado -  $W$ ), e/ou ligeiros aumentos do EMG, que podem incluir ondas teta, alfa e/ou frequências superiores a 16 Hz, excluindo os fusos de sono [13].

Na figura 2 apresentamos 12 segundos de sinal onde se pode observar um micro despertar, com a duração de 6 segundos, onde poderemos destacar, o aumento do tónus muscular e o visível incremento da frequência dos sinais de EEG.

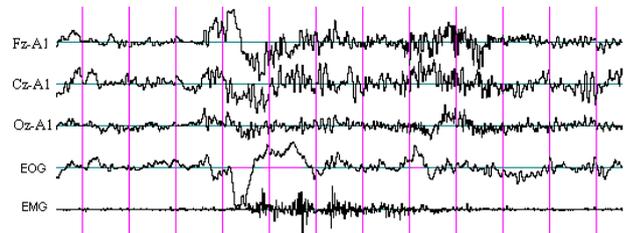


Figura 2. Época de 12 segundos de sinal, onde se encontra presente um micro despertar de 6 segundos.

Para a detecção dos micro despertares, são usadas duas das três derivações de EEG referidas, central e occipital e o EMG submentoniano.

Após a extracção dos parâmetros, que para o caso em estudo, consiste fundamentalmente em realizar uma estimativa da frequência fundamental dos sinais de EEG (central e occipital) e da potência do EMG, estamos perante um problema de classificação, em que não é grande o conhecimento *a priori* das propriedades estatísticas dos parâmetros, pelo que não é aconselhável o uso de classificadores óptimos. Optamos assim, por usar um classificador baseado no método das K-médias. O último bloco do sistema, é constituído por um módulo de classificação por contexto, que permite a recuperação de falsas detecções, o refinamento da classificação efectuada

e a determinação mais exacta, da duração do micro despertar.

### C.1. Estimativa da frequência fundamental para segmentos de curta duração

Verifica-se que para segmentos de curta duração de EEG, a hipótese de estacionariedade é em geral verificada com razoável aproximação [14], sendo este tipo de sinais conhecidos como quase-estacionários. Assim, o sinal de EEG, é seccionado em segmentos de dois segundos. Ao fim de cada segundo, para o segmento constituído pelos dois segundos anteriores de sinal, é calculada uma estimativa da frequência fundamental, existindo portanto, para dois segmentos consecutivos, sobreposição de um segundo de sinal.

O método usado para a obtenção da estimativa da frequência fundamental foi desenvolvido a partir de um estimador apresentado por Rabiner [15]. Os princípios básicos do método são os seguintes:

- Os sinais de EEG são processados, de forma a gerarmos um conjunto de sequências de impulsos, com base na detecção dos máximos e mínimos locais do sinal, que contêm a periodicidade do sinal original, sendo desprezada a informação irrelevante.
- A partir do conjunto de estimativas obtidas, é calculado o histograma de frequências, que permite a determinação da frequência fundamental e das frequências de menor significado presentes em cada segmento.

Na figura 3, para uma época de 400 segundos, apresenta-se o valor da frequência fundamental normalizada, determinada ao fim de cada segundo, para o canal occipital. Note-se a presença de dois aumentos bruscos da frequência, correspondentes a dois micro despertares.

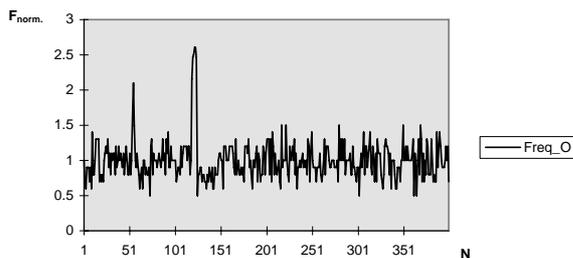


Figura 3. Frequência fundamental normalizada determinada ao fim de cada segundo, para a derivação occipital.

### C.2. Estimativa da potência do EEG e do EMG

O segundo parâmetro que pretendemos retirar dos sinais de EEG, deverá permitir a sua caracterização em termos de amplitude. Este parâmetro permite distinguir eventuais artefactos, que não estejam associados a micro despertares.

O parâmetro usado, consiste numa estimativa da potência do sinal. A cada segmento de um segundo de sinal, é

aplicada uma não linearidade ( $(\cdot)^2$ ), que tem por função fazer uma translação da banda do sinal (que se admite de banda limitada) para a banda base, criando ao mesmo tempo um número infinito de bandas (réplicas) a  $kf_s$ . Para se eliminar as réplicas, é usado um filtro passa baixo, obtendo-se na sua saída uma medida da potência do sinal de EEG.

O filtro passa baixo é um IIR, do tipo Chebyshev, com um único pólo sendo a sua frequência de corte de 1 Hz, pois apenas nos interessa a envolvente do sinal e esta apresenta variações lentas. A saída do passa baixo é amostrada, sendo tomada uma em cada 100 amostras (o dobro da frequência do passa baixo), existindo portanto uma decimação (100:1). Para cada duas amostras, correspondentes a um segundo de sinal é calculada a média.

O EMG também é caracterizado pela estimativa da potência do sinal. Pode-se verificar através da análise do sinal, que a amplitude do EMG, durante a ocorrência de um artefacto ou na sequência de um micro despertar, sofre normalmente variações muito apreciáveis ao longo do tempo, que são facilmente identificadas, através da análise da estimativa da potência do sinal. O método de estimação da potência usado para este sinal, é semelhante ao apresentado anteriormente. Na figura 4 apresentamos a estimativa para a potência do EMG, calculada para o segmento de 400 segundos já referido. Pode-se notar de novo, dois picos claros, correspondentes a dois micro despertares.

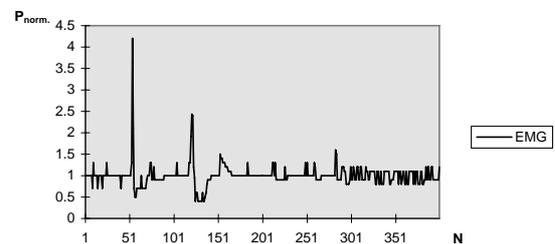


Figura 4. A estimativa da potência (normalizada) do EMG, calculada para segmentos de um segundo, determinada para uma época de 400 segundos.

### C.3. Detecção de transitórios em segmentos de EEG

Se analisarmos na figura 5, a representação das amostras, obtidas a partir dos parâmetros extraídos para a derivação occipital, em duas dimensões (estimativa da frequência fundamental e da potência do EEG (normalizadas)), para uma época de 10 minutos de sinal, sendo conhecido *a priori*, a existência no segmento de dois micro despertares, verificamos claramente a existência de duas classes, que passaremos a denominar de *Arousal* e *NArousal*. Em situações deste tipo, em que as amostras tendem a agrupar-se densamente em torno de um número muito limitado de padrões típicos, a classificação por

mínima distância, apresenta-se normalmente como um bom método para resolver o problema da classificação.

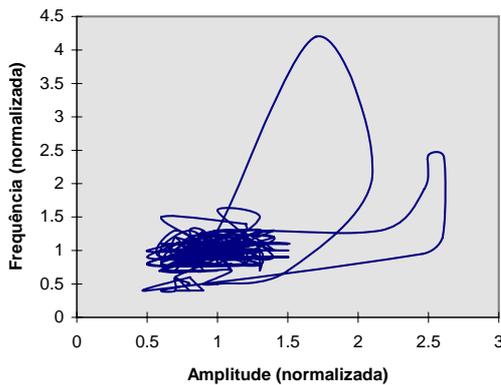


Figura 5. Representação de 600 amostras em duas dimensões (frequência fundamental e estimativa da potência do EEG), obtidas a partir da derivação occipital, para uma época em que são conhecidos dois micro despertares.

A principal desvantagem deste método tem a ver com o desconhecimento *a priori* dos aglomerados, conhecimento que é necessário, para que depois possamos efectuar a distribuição das amostras pelo conjunto de aglomerados existentes. Para o algoritmo iterativo, conhecido por método das K-médias, não é necessário conhecer *a priori* os aglomerados.

O primeiro passo do método que desenvolvemos com base no algoritmo das K-médias, consiste em seleccionar os  $K$  centros de aglomerados  $p_j(1)$ ,  $i=1,2,\dots,K$ , arbitrariamente, podendo ser, por exemplo, as  $K$  primeiras amostras. Seguem-se três diferentes passos, que passamos a descrever:

- 1 - Para uma dada iteração  $i$  a amostra  $x$  é classificada pela regra:

$$x \in A_j(i) \text{ se } \|x - p_j(i)\| > \|x - p_i(i)\| \text{ para todo o } i \neq j$$

- 2 - No segundo passo, são calculados os novos centros dos aglomerados, por forma a que se obtenha a minimização da soma dos quadrados das distâncias de todas as amostras e para todos os aglomerados, determinando-se o valor médio das amostras que pertencem a cada aglomerado:

$$p_j(i+1) = \frac{1}{N_j} \sum_{x \in A_j} x \quad j=1,2,\dots,k$$

- 3 - No terceiro passo, é comparado o conjunto de centros de aglomerados obtidos na presente iteração, com os centros obtidos na iteração anterior. Se forem diferentes retoma-se o passo 1, caso contrário, o algoritmo convergiu terminando-se o processo. A convergência, também poderia ser verificada, através da avaliação do número de

amostras que mudam de classe, em duas iterações consecutivas.

Atendendo a que o algoritmo é iterativo, foi necessário tomar alguns cuidados, para tornar possível a sua realização em tempo real. O primeiro problema que se põe, é que para o algoritmo apresentado, não existe nenhuma prova geral de convergência. Por outro lado, a eficácia deste algoritmo, é determinada pelo número de amostras seleccionadas, pelos centros de aglomerados que inicialmente se escolhem e pela ordenação das amostras. Com o objectivo de optimizarmos os tempos de computação, optou-se por aplicar o algoritmo, apenas quando a distância euclidiana entre duas amostras sucessivas for superior a um limiar prédefinido, e apenas para as 10 amostras anteriores à primeira das amostras em estudo e para as 20 seguintes. O número de centros usados foi de dois, e o número de iterações foi limitado a 15, número que é atingido, caso não se tenha obtido convergência com um menor número de iterações.

#### C.4. Regras de contexto

A validação dos *micro despertares*, é feita num módulo de classificação por contexto que incorpora informação usada pelos clínicos, e que se segue ao classificador descrito na subsecção anterior. A entrada deste módulo é constituída pela indicação da classe (*Arousal* e *NArousal*) atribuída, pelos parâmetros extraídos do EMG e do EEG, por uma estrutura que armazena a quantificação dos últimos *bursts* de actividade alfa e de fusos de sono, a indicação temporal das respectivas ocorrências e a classificação (estádio de sono) atribuída à última época. O módulo mantém também actualizada uma estrutura com indicação da duração e referência temporal da ocorrência do último despertar. As regras de contexto são aplicadas após a detecção da primeira época *NArousal*, depois de se ter registado uma sequência de amostras classificadas como *Arousal*. São aplicadas 7 regras de contexto que se expõem de seguida:

- Verifica-se o número de amostras classificadas como *Arousal*. Se o número for inferior a 3 ou superior a 15, o micro despertar, não é contabilizado, pois considera-se que, para o primeiro caso, o número mínimo de segundos (3) necessários para que o despertar possa ser distinguido, não foi atingido, e para o segundo, considera-se que a transição não é um micro despertar, mas sim uma transição ao estágio de sono  $W$ .
- Se o micro despertar foi validado, apesar da primeira regra, verifica-se qual o estágio atribuído à época<sup>1</sup>. Caso seja o  $W$ , o despertar só é considerado se nos 10 segundos anteriores ao início do transitório não tiver sido detectada a presença da actividade alfa.
- Uma terceira regra, que actua independente da anterior, procura verificar se entre a detecção em estudo e

<sup>1</sup> Na prática verifica-se a existência de um *burst* de actividade alfa superior a 1 segundo, nos últimos 10 segundos, qualquer que seja o estágio atribuído à época em análise.

o último micro despertar, existe um período de latência de pelo menos 10 segundos. Com esta regra, procura-se distinguir a presença efectiva de um micro despertar, do efeito residual de despertares anteriores, ou distinguir estes transitórios do sono alfa.

- A quarta regra<sup>2</sup> é activada, caso a época onde o micro despertar é detectado seja classificada de REM. O despertar apenas é contabilizado se em simultâneo com o aumento da frequência nos canais de EEG, se verificar o aumento da potência do sinal do EMG.

- Na quinta regra de contexto, verifica-se para as amostras que proporcionaram a transição da classe *NArousal* para *Arousal*, se o aumento da potência do sinal foi acompanhado pelo aumento da frequência fundamental. Caso este último parâmetro não aumente de valor, a mudança de classe deveu-se apenas ao aumento da potência do EEG, não sendo assim, considerada a detecção, pois estamos na presença de um artefacto.

- A sexta regra de contexto, testa se no intervalo em que o micro despertar foi assinalado, ocorreu em simultâneo um fuso de sono. Caso a resposta seja afirmativa o transitório não é considerado.

- Independentemente da classificação do módulo anterior, também são considerados como micro despertares, os *bursts* de actividade alfa com duração superior a 3 segundos e que ocorrem isoladamente, devendo assim, como referimos, existir um período de latência entre *bursts* de, pelo menos, 10 segundos.

### III. RESULTADOS

Foram usados 8 registos, sem ter sido feita qualquer selecção especial, recolhidos no Laboratório de Sono do Serviço de Neurofisiologia do Hospital Geral de Santo António do Porto. De cada registo foi escolhido aleatoriamente um segmento contínuo de 2 horas e 30 minutos. A totalidade das 2400 épocas de sinal, foram analisadas e classificadas, a partir do registo em papel por especialistas do Serviço. Os resultados produzidos pelo sistema, foram comparados com a análise dos especialistas.

#### A. Avaliação do Classificador

Para a topologia escolhida, a concordância obtida com o próprio conjunto de treino é de 97.4 % e para o conjunto de validação obtivemos 93.6 %.

Na tabela 3, apresentamos para o conjunto dos registos usados na avaliação do classificador, a matriz de confusão obtida a partir da classificação fornecida pela rede e a efectuada pelos especialistas, por inspecção visual, e na tabela 4 apresentamos, para os diferentes estádios, os erros, a respectiva percentagem, o total de detecções para cada estádio, indicadas pelo especialista, a concordância e a sensibilidade. Da análise das tabelas referidas, ressalta

que o maior número de falsos positivos surge para o estádio 2, correspondendo a épocas classificadas pelo especialista como estádio 1 e 3, e verificando-se também um elevado número de falsos negativos para o estádio 1, correspondendo a épocas classificadas pela rede como estádio 2. O segundo maior número de falsos positivos está associado à detecção do estádio 3, classificados pelo especialista como estádio 2.

| Sistema Clínico | Est. 0     | Est. 1/5   | Est. 2      | Est. 3     | Est. 4     | Total       | F N. % |
|-----------------|------------|------------|-------------|------------|------------|-------------|--------|
| Est.- 0         | <b>142</b> | 0          | 26          | 4          | 0          | 172         | 16.6   |
| Est.- 1/5       | 10         | <b>256</b> | 62          | 0          | 0          | 328         | 25.4   |
| Est.- 2         | 29         | 27         | <b>1272</b> | 53         | 0          | 1381        | 8.0    |
| Est.- 3         | 0          | 0          | 5           | <b>308</b> | 3          | 316         | 2.1    |
| Est.- 4         | 0          | 0          | 0           | 8          | <b>195</b> | 203         | 4.0    |
| Total           | 181        | 283        | 1365        | 551        | 551        | <b>2400</b> |        |
| F. P. %         | 21.5       | 9.5        | 6.8         | 17.4       | 1.5        |             |        |

Tabela 3. Matriz de confusão para a rede de classificação.

| Estádio | 0    | 1/REM | 2    | 3    | 4    |
|---------|------|-------|------|------|------|
| Erros   | 69   | 99    | 202  | 73   | 11   |
| % erro  | 38.1 | 35.0  | 14.8 | 19.6 | 5.5  |
| T.D.E.  | 172  | 328   | 1381 | 316  | 203  |
| Conc.   | 82.6 | 78.0  | 92.1 | 97.5 | 96.0 |
| Sens.   | 78.0 | 90.5  | 93.1 | 82.6 | 98.5 |

Tabela 4. Avaliação do classificador (T.D.E. - Total de detecções do especialista, Conc. - Concordância, Sens. - Sensibilidade).

Globalmente os resultados são bons, mesmo quando comparados com trabalhos publicados recentemente. A concordância global é de 90.5 %, descendo para 89.4 %, quando se separam os estádios 1 e REM. Na figura 6, apresentamos para um dos registos usados na validação, o hipnograma fornecido pelo sistema e o produzido pelo clínico por inspecção visual.

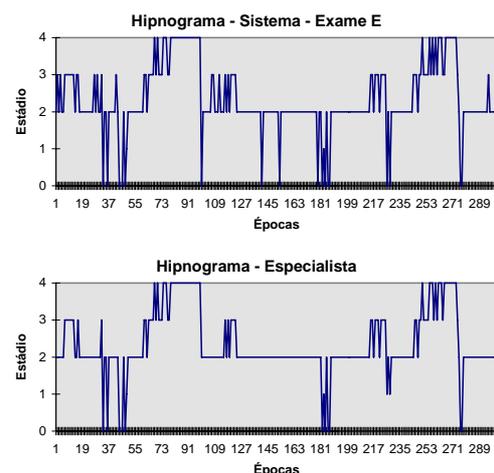


Figura 6. Hipnograma sistema/especialista.

<sup>2</sup> Esta regra apenas é implementada após se obter a classificação da época, a que o despertar pertence.

### B. Avaliação dos métodos de supervisão da classificação

Na figura 7, para facilidade de análise, apresenta-se para um dos exames, a função  $I-y$ , em que  $y$  é a saída da rede de supervisão. A partir de várias comparações estabeleceu-se o limiar, a partir do qual se considera que a rede está a extrapolar e que é de 0.25. Para este valor, foram detectados para o conjunto dos registos, 200 vectores, que se estima que não foram apresentados à rede na fase de treino. Destes 200 vectores, 75 correspondem a vectores de entradas mal classificadas, pela rede neuronal, valor que corresponde a 33.0 % do total de erros (227 erros) produzidos pelo classificador.

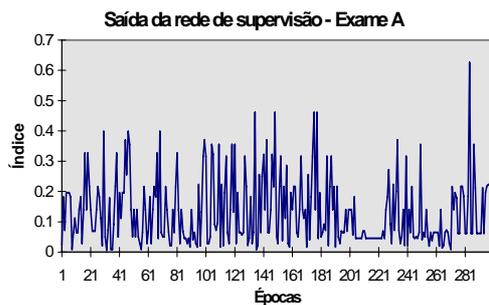


Figura 7. Saída transformada da rede de supervisão.

Da análise da distância euclidiana, calculada para determinar a coerência das saídas da rede de classificação, concluímos que o limiar 1.1 era o melhor compromisso entre a detecção de erros de classificação e a ocorrência de falsos positivos. Para o conjunto dos registos, temos que, para o limiar escolhido, são detectadas 120 saídas ambíguas (5 % do total das épocas), das quais 48 (21 % do total de erros) correspondem a erros produzidos pelo classificador. Este resultado também é muito interessante, na medida que a inspeção visual de 5 % do total de páginas permite a recuperação de 21 % dos erros. Na figura 8 apresentamos, para um dos registos as distâncias calculadas para cada saída.

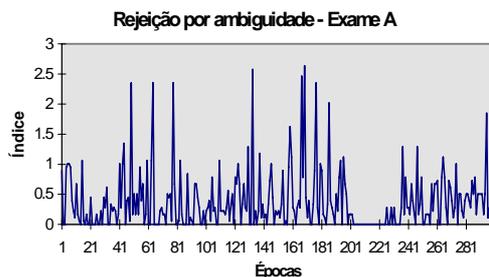


Figura 8. Distâncias euclidianas calculadas para cada saída da rede de classificação.

### C. Avaliação do detector de micro despertares

Para o conjunto dos registos, o sistema apresenta 194 detecções, que correspondem a 172 positivos, 22 falsos positivos e 23 falsos negativos. Temos assim, 46 decisões erradas (23.2 %), ao que corresponde uma concordância

de 88.6 % e a sensibilidade é de 88.2 %. Através da análise dos resultados apresentados, pode-se concluir do bom desempenho do detector. Na figura 9 apresentamos para um dos registos as detecções produzidas pelo especialista e as detecções geradas pelo sistema.

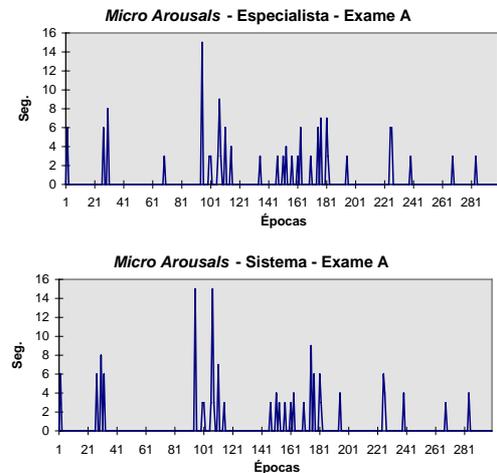


Figura 9. Evolução dos micro despertares assinalados pelo especialista e registados pelo detector automático.

## IV. CONCLUSÕES

O trabalho apresentado neste artigo, enquadra-se no vasto esforço de investigação e desenvolvimento nas áreas de análise e classificação automática do EEG de sono. As contribuições específicas deste trabalho, consistem na apresentação de novos métodos de caracterização dos sinais, e numa proposta de um classificador supervisionado, baseado em redes neuronais, o qual apresenta um elevado desempenho, tanto sob o ponto de vista da classificação, como da supervisão da classificação. Atendendo às limitações intrínsecas do modelo de classificação tomado como base, foi também desenvolvido um sistema de detecção de micro despertares, que permite uma análise integrada do EEG de sono, nomeadamente a detecção das transições à vigília durante curtos instantes.

Os resultados demonstram, por um lado, que os detectores produzem genericamente resultados fiáveis, e por outro, que as redes neuronais constituem um interessante e simples modelo, quando treinadas com a informação certa, para incorporar a informação usada pelo clínico, num sistema automático de classificação.

A comparação possível com outros sistemas apresentados na literatura, permite-nos dizer, que o nosso sistema produz uma melhor distinção dos estádios 1/REM e 2, justificada, em nossa opinião, pela melhor parameterização do sinal, nomeadamente, pela inclusão do parâmetro LVMF, dos índices de relevância de banda e do resultado do detector dos complexos K. Note-se no entanto, da grande subjectividade das comparações efectuadas, pois são estabelecidas a partir de dados diferentes, sendo distintas as características dos sinais, sendo igualmente diferente os tempos relativos de duração

de cada estúdio. No entanto, é ainda de realçar, que a concordância obtida pelo nosso sistema, com a classificação gerada por um especialista, é da ordem dos 90 %, valor semelhante à concordância que se obtém entre dois especialistas, de um mesmo laboratório.

Os métodos de supervisão da classificação automática produziram resultados muito interessantes. Para a rede de supervisão, e para um total de 227 erros produzidos pela classificação automática, foram detectadas 200 extrapolações (8.3 % do total de épocas analisadas), das quais 75 correspondem a erros de classificação. Este resultado é notável, se considerarmos que a análise por parte do especialista de cerca de 8 % do total das épocas, permite a recuperação de 33 % dos erros.

O método de análise das saídas da rede de classificação, permitiu a detecção 120 saídas ambíguas (5 % do total de épocas analisadas), das quais 48 correspondem a erros produzidos pelo classificador. Para este método, a análise do especialista, de 5 % do conjunto de épocas, permite a recuperação de 21 % dos erros verificados.

Os métodos apresentados, fornecem resultados complementares, na medida que cada um permite a recuperação de um número significativo de erros diferente. A informação disponibilizada pelos métodos, fornece ao utilizador um importante indicador da fiabilidade do classificador, permitindo a aceitação ou rejeição fundamentada, da classificação automática produzida. Esta particularidade do nosso sistema, é tanto mais importante, na medida em que, para o modelo de processamento hierárquico adoptado, os pequenos erros do primeiro nível de processamento reflectem-se de uma forma significativa no segundo nível, não havendo meio de controlar esta propagação de erro. Assim, por exemplo, quando o sinal de entrada tem má qualidade, é grande a probabilidade dos processos de detecção funcionarem mal, o que provoca mau desempenho do classificador, que pode deste modo, ser facilmente detectado.

Para o detector de micro despertares, o acordo entre a detecção por inspecção visual e a detecção automática, para o conjunto de registos, varia entre os 85 % e os 100%. A concordância média é de 88.6 %. Verificou-se que o detector tem um desempenho muito elevado, quando os micro despertares, ocorrem separados por intervalos de tempo significativos. O maior número de falsos positivos, ocorre geralmente em sono lento, nomeadamente no estúdio 4, e está relacionado com a baixa frequência dos sinais.

#### REFERENCES

[1] J. Principe, S. Gala, T. Chang. 1989. "Sleep Staging Automaton Based on the Theory of Evidence". *IEEE Transactions on Biomedical Engineering*. 36:503-509.

[2] T. Chang, J. Smith, J. Principe. "A Layered Processing Model for Knowledge-Base Contextual Interpretation of Multichannel EEG/EOG Signals." 239-243.

[3] A. M. Tomé. 1990. "Sistema para Microanálise e Classificação Automática do Electroencefalograma do Sono". Tese de Doutoramento, Universidade de Aveiro, Aveiro.

[4] N. Schaltenbrand, R. Lengelle, J. P. Macher. 1993. "Neural Network Model: Application to Automatic Analysis of Human Sleep". *Computers and Biomedical Research*. 26:157-171.

[5] J. Principe, T. Chang, S. Gala, A. Tomé. 1992. "Information Processing Models for Sleep Staging". *Int. J. Expert Systems*.

[6] A. Rechtschaffen, A. Kales. 1968. "A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects". US Government Printing Office Washington.

[7] O. R. Pacheco. 1996. "Sistema Assistido por Computador para Classificação do Electroencefalograma do Sono e Detecção de Micro Despertares". Tese de Doutoramento, Universidade de Aveiro, Aveiro.

[8] B. Hjorth. 1970. "EEG Analysis Based on Time Domain Properties". *Electroencephalography and Clinical Neurophysiology*. 29: 306-310.

[9] A. Pinho. 1993. "NSL Uma linguagem para o desenvolvimento e simulação de redes neuronais artificiais". Publicação Interna-DETUA Universidade de Aveiro.

[10] D. E. Rumelhart, G. E. Hinton, R. J. Williams. 1986. "Learning Representations by Backpropagating Errors". *Nature*. 323(9).

[11] J. A. Leonard, M. A. Kramer, L. H. Ungar. 1992. "Using radial basis functions to approximate a function and its error bounds". *IEEE Transactions on Neural Networks*. 3(4): 624-627.

[12] H. Ney. 1995. "On the Probabilistic Interpretation of Neural Network Classifiers and Discriminative Training Criteria". *IEEE Transactions on Pattern Analysis and machine Intelligence*. 17(2): 107-119.

[13] American Sleep Disorders Association. 1992. "EEG Arousals: Scoring Rules and Examples". *Sleep*. 15:74-101.

[14] B. H. Jansen, A. Hasman, A. Lenten. 1980. "Piecewise EEG Analysis: An Objective Evaluation". *Int. J. Bio-Medical Computing*. 12:17-27.

[15] L. R. Rabiner, R. W. Schafer. 1978. *Digital Processing of speech signals*. Prentice-Hall, Englewood Cliffs, NJ.