

Mestrado em Engenharia Informática
Dissertação
Relatório Final

BrainSleep: Sistema móvel para detecção de estados de sonolência baseado em ondas cerebrais

Paulo Jorge Pereira Teixeira
paulojpt@student.dei.uc.pt

Orientador:
Professor Doutor César Alexandre Domingues Teixeira

1 de Setembro de 2014



FCTUC DEPARTAMENTO
DE ENGENHARIA INFORMÁTICA
FACULDADE DE CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE DE COIMBRA

"O primeiro passo para o conhecimento é sabermos que somos ignorantes."

Cícero

Resumo

O objetivo deste estágio consistiu em desenvolver uma aplicação para o sistema operativo Android que conseguisse detetar o estado de sonolência num indivíduo, baseado em informação cerebral adquirida através do Eletroencefalograma (EEG). A deteção de estado de sonolência é de extrema importância pois poderá evitar as graves consequências que o sono pode trazer em certas tarefas do nosso dia-a-dia. Espera-se que esta aplicação tenha uma grande importância prática, uma vez que o sono é uma das principais causas de acidentes fabris e de viação.

Em primeiro plano, este relatório reporta um estudo em torno da neurofisiologia do sono, onde são apontados os diferentes estados do sono e as doenças a si associadas. É também reportado um estudo acerca das metodologias de aquisição de biosinais importantes para o estágio em causa. Neste estudo demos especial importância ao eletroencefalograma (EEG), uma vez que foi a principal fonte de informação utilizada neste estágio. Visando a classificação de estados de sonolência, foi feito um estudo sobre as metodologias mais usadas para extração de características e para reconhecimentos de padrões (tais como máquinas de vetor de suporte (SVM), redes neuronais artificiais, entre outras).

Relativamente aos dados, foram elaborados dois estudos. O estudo inicial incidiu sobre 15 indivíduos, onde se retiraram algumas informações importantes referentes às características e zonas que melhor classificam o sono. O segundo estudo, foi com 8 indivíduos onde se direccionou mais para análise e classificação, para posteriormente se utilizar o modelo treinado para a implementação em Android.

Do ponto de vista técnico, foi assemblado o sistema total necessário para aquisição e processamento de sinais formado pelo equipamento *Emotiv EEG neuroheadset* e pelo dispositivo móvel Asus Memo Pad 7 a correr o sistema operativo Android 4.1.1. O *Emotiv EEG neuroheadset* tem capacidade para efetuar a leitura de 14 posições cerebrais assim como as leituras de dois giroscópios. Ao nível de *software* foi desenvolvido o código necessário para a aquisição, graficação, e extração de algumas características dos sinais de EEG.

No projeto é possível visualizar o sinal dos elétrodos do *Emotiv EEG neuroheadset*, sendo que os mesmos são apresentados graficamente no dispositivo móvel Asus Memo Pad 7. Foi desenvolvido também um programa para obtenção dos valores dos elétrodos numa plataforma Windows para posteriormente efetuar-se a leitura de dados e a sua gravação numa base de dados.

O sistema móvel deteta o estado de sonolência de um indivíduo. Para tal, foi necessário aplicar classificadores de maneira a poder classificar os sinais com a precisão adequada, isto é, com sensibilidade elevada e com uma taxa de falsos alarmes reduzida.

Palavras-Chaves

Classificação de biosinais, Android, *Emotiv*, Neurofisiologia do sono, Eletroencefalograma.

Abstract

The objective of this dissertation is to develop an application for the Android operating system that can detect early stages of sleepiness in individual, based on the information acquired by brain Electroencephalogram (EEG) and head motion information provided by gyroscopes. The states of drowsiness detection are extremely important because it can avoid the serious consequences that sleep can bring on certain daily tasks. This application will have a great practical importance, since sleep is a major cause of industrial and driving accidents.

This interim report presents a study about the neurophysiology of sleep, highlighting the different states of sleep and its associated diseases. It also reports a study about the methods for biosignals acquisition (important for the dissertation in question). In this study, we give particular importance to electroencephalogram (EEG), because it will be the main source of information to use during this project. Aiming the classification of the drowsiness stage, a study on the methodologies most commonly used in literature for feature extraction and pattern recognition (such as support vector (SVM) machines, artificial neural networks, etc.) has been done.

Relation to the data, two studies was conducted. The initial study focused on 15 users, which withdrew from some important information relating the features and areas that best classify sleep. The second was with 8 users where it has directed more for analysis and classification, later to use the train model for deployment on Android.

From the technical point of view, at the moment, we assembled the total system required for acquisition and signal processing, formed by Emotiv device and the mobile Asus Memo Pad 7 running Android 4.1.1 operating system. The EEG Emotiv neuroheadset has 14 cerebral electrode and 2 gyroscopes readings that allows multiple acquisitions. At the software level we developed code for the acquisition, and displaying of the EEG and head movements signals.

Is possible to view the signal from the Emotiv EEG electro neuroheadset. Signals are presented graphically in the mobile Asus Memo Pad 7. A program was also developed to obtain the values of the electro in Windows platform and consequently reading of individuals data and record them in a database.

The mobile system to detect the state of sleepiness. For this it is necessary to apply classifiers and classify the signals with appropriate accuracy, i.e. with high sensitivity and a reduced rate of false alarms.

Key-Word

Classification bio-signal, Android, Emotiv, Neurophysiology of sleep, eletroencephalogram.

Agradecimentos

Queria agradecer em primeiro lugar aos meus pais e irmãos que tudo têm feito por mim e me proporcionaram o prazer de percorrer este longo percurso, estando sempre presentes nos bons e maus momentos. Sem esquecer um agradecimento também à Joana Monteiro que me tem acompanhado nesta grande aventura e está sempre ao meu lado.

Não posso deixar de agradecer ao meu orientador Doutor César Teixeira por me ter acompanhado e por me ter feito crescer na minha formação académica.

Ao Doutor Francisco Sales e ao grupo de trabalho da Unidade de Monitorização em Epilepsia e Sono (UMES) do Centro Hospitalar e Universitário de Coimbra (CHUC), pois sem eles não seria possível ter conseguido obter o sucesso neste projeto.

Às restantes pessoas que me ajudaram, de uma forma ou de outra, como a Marta Monteiro, a Maria Cruz, o Ricardo Simões e os meus amigos, o meu obrigado.

Índice

Capítulo 1	Introdução	1
1.1	Motivação.....	1
1.2	Objetivos	1
1.3	Fases do estágio.....	2
Capítulo 2	Estado da Arte	3
2.1	Classificação do sono.....	3
2.2	Outras abordagens para detecção de sonolência.....	4
2.2.1	Polissonografia	4
2.2.2	Eletroencefalograma EEG	5
2.2.3	Análise dos movimentos dos olhos (<i>Eye tracking technology</i>).....	7
2.2.4	Variabilidade da frequência cardíaca (HRV)	8
2.2.5	Acelerómetros em dispositivos móveis	9
2.3	Características do EEG	10
2.3.1	Características do domínio do tempo	10
2.3.1.1	Medidas Estatísticas	10
2.3.1.2	Energia.....	11
2.3.2	Características do domínio da frequência	11
2.3.2.1	Potências Relativas.....	12
2.3.2.2	Coeficientes Hjorth	13
2.3.2.3	Resumo	13
2.4	Classificadores	13
2.4.1	Máquina de vetor de suporte (SVM).....	14
2.4.2	Redes neuronais artificiais	17
2.4.3	Redes Bayesianas.....	19
2.4.4	K-Vizinhos Mais Próximos	21
2.4.5	Modelos ocultos de Markov.....	22
2.4.6	Resumo Classificadores	24
Capítulo 3	Materiais e Métodos	25
3.1	Hardware de aquisição Emotiv	25
3.2	Transmissão de dados	26
3.3	Definição de requisitos.....	26

3.3.1.	Análise de MoSCow	27
3.3.2.	Funcionalidades do produto.....	27
3.3.3.	Requisitos Funcionais.....	27
3.3.4.	Requisitos não funcionais	28
3.3.5.	Requisitos de interface externa	29
3.4	Desenho da solução.....	29
3.4.1.	Desenho do projeto.....	29
3.4.2.	Tecnologias	30
3.4.3.	Ferramentas e Bibliotecas de Apoio.....	31
3.4.4.	Testes da aplicação.....	31
3.5	Seleção de elétrodos e extração de características	31
3.5.1.	Seleção de elétrodos.....	31
3.5.2.	Transformada rápida de Fourier.....	32
3.5.3.	Análise contínua de sinais	33
3.6	Métodos de análise.....	35
3.6.1.	Curva de ROC, matriz de confusão e métricas de performance	35
3.6.2.	Kruskal-Wallis	37
3.7	Teste e validação	38
Capítulo 4	Resultados & Discussão	39
4.1	Estudo Preliminar	39
4.1.1	Descrição dos dados.....	39
4.1.2	Análise Discriminatória.....	39
4.2	Estudo com dados recolhidos no Centro Hospitalar e Universitário de Coimbra	45
4.2.1	Descrição dos dados.....	45
4.2.2	Análise Discriminatória.....	46
•	Eléctrodo F3.....	46
•	Eléctrodo F4.....	48
•	Eléctrodo O1.....	50
•	Eléctrodo O2.....	52
•	Análise do efeito dos elétrodos.....	54
•	Análise do efeito da idade.....	58

•	Resumo Geral.....	61
4.3	Classificadores	61
4.3.1	Bayes	63
4.3.2	Redes Neurais Artificial.....	64
4.3.3	K-Vizinhos mais próximos.....	65
4.3.4	Máquina de vetor de suporte (SVM).....	68
4.3.5	Resumo.....	70
4.4	Aplicação móvel para classificação de estados de sonolência em tempo-real.....	70
Capítulo 5 Conclusões.....		74
Referências.....		76
Anexos.....		82
Anexo A	Análise de Riscos.....	83
Anexo B	Testes a aplicação	85
Anexo C	Cronograma.....	87

Lista de Imagens

Figura 1: Ciclos dos vários estados do sono (adaptado de [4]).	4
Figura 2: Vista lateral (esquerda) e de topo (direita) da colocação dos elétrodos segundo o standard 10-20 [7, 8].	5
Figura 3: Medida Bipolar [7].	6
Figura 4: Medida unipolar [7].	6
Figura 5: Imagem EEG estado 1 [9].	7
Figura 6: Monitorização da câmara de leitura de infravermelhos.	7
Figura 7: Várias posições da câmara por forma a perceber a perceção da pupila em relação à reflexão da córnea [60].	7
Figura 8: Deteção de sonolência através da análise de <i>Eye Tracking</i> (Software Drive State Eléctrodo [57]).	8
Figura 9: Representação de um eletrocardiograma[64].	8
Figura 10: Curvas relativas ao resultado do cálculo da curtose.	11
Figura 11: Hiperplano numa rede SVM [23].	15
Figura 12: Exemplo de uma solução de um problema não linear	16
Figura 13: Exemplo de uma rede ANN [28].	17
Figura 14: Implementação de retropropagação [29].	18
Figura 15: Exemplo de uma rede bayesiana[33].	20
Figura 16: Exemplo de KNN para um K=5.	21
Figura 17: Modelo sem restrições [53].	23
Figura 18: Modelo sequencial [53].	23
Figura 19: Modelo paralelo [53].	23
Figura 20: Sistema 10-20 de posicionamento [8]. Os pontos a verde representam os pontos de leitura do <i>hardware Emotiv</i> .	25
Figura 21: Desenho da arquitectura de alto nível.	29
Figura 22: Análise contínua de sinais.	34
Figura 23: Exemplificação da obtenção da curva ROC [68]. A linha vertical indica um limiar arbitrário e variável. A área a vermelho representa os verdadeiros positivos, a área a azul os verdadeiros negativos, a região a azul esverdeado (ciano) os falsos negativos e a região a rosa os falsos positivos [79].	35
Figura 24: Matriz de confusão genérica [69].	36
Figura 25: Curva Roc dos resultados relativos à combinação Pz-Oz.	40
Figura 26: Curva Roc dos resultados.	40
Figura 27: Características Fpz-Cz.	41
Figura 28: Características Pz-Oz.	42
Figura 29: As quatro melhores características do eléctrodo Pz-Oz em função do sexo dos indivíduos.	44
Figura 30: Valor máximo, mínimo e médio das melhores características.	44
Figura 31: Características do eléctrodo F3.	47

Figura 32: Evolução temporal das potências relativas nas diversas bandas para o eléctrodo F3.....	48
Figura 33: Valores obtidos nas características F4 referentes ao sexo.....	48
Figura 34: Evolução temporal das potências relativas nas diversas bandas para o eléctrodo F4.....	50
Figura 35: Detalhe das características referentes ao sexo e eléctrodo O1.....	51
Figura 36: Evolução temporal das potências relativas nas diversas bandas para o eléctrodo O1.....	52
Figura 37: Características O2 relativas ao sexo.....	53
Figura 38: Evolução temporal das potências relativas nas diversas bandas para o eléctrodo O2.....	54
Figura 39: Dados relativos aos eléctrodos a estudar e qual nos apresenta melhores resultados.....	55
Figura 40: Valores finais de características, sendo apresentado também o máximo mínimo e médio.	56
Figura 41: Resultados finais de junção de todos os valores das 4 melhores características.....	57
Figura 42: Análise relativamente ao sexo.....	57
Figura 43: Dados relativos a idades menores que dezoito anos, entre dezoito e trinta anos e por fim idades superiores a trinta anos. Senso o O1 o eléctrodo em análise.....	60
Figura 44: Dados relativos a idades menores que dezoito anos, entre dezoito e trinta anos e por fim idades superiores a trinta anos neste caso para o eléctrodo O2.....	60
Figura 45: Análise dos eléctrodos em estudo com as melhores características.....	61
Figura 46: Passos seguidos para o desenvolvimento dos classificadores.....	62
Figura 47: Resultados obtidos pelo classificador bayes para duas características.....	63
Figura 48: Rede neuronal com duas entradas e uma saída.....	64
Figura 49: Curva ROC para ANN.....	65
Figura 50: Informação curva ROC, como apresentado na secção 3.6.1.....	65
Figura 51: Análise pormenorizada dos valores de K.....	66
Figura 52: Erros associados ao valor de K.....	67
Figura 53: Distribuição dos padrões de teste e superfícies de decisão definidas pelo algoritmo KNN com K=10.....	68
Figura 54: Verificação do melhor valor de C.....	68
Figura 55: Curva ROC para o classificador SVM.....	69
Figura 56: Classificadores SVM para o valor de C=9.....	69
Figura 57: Ecrãs iniciais.....	71
Figura 58: Janela da aplicação que mostra os sinais dos eléctrodos e giroscópios.....	71
Figura 59: Dados de um eléctrodo em específico.....	72
Figura 60: Qualidade Signal.....	72
Figura 61: Janelas da aplicação que mostram as características extraídas do EEG.....	73

Lista de Tabelas

Tabela 1: Características do sono NREM.	3
Tabela 2: Variáveis eletrofisiológicas com a frequências e amplitudes [5].....	5
Tabela 3 Várias funções de Kernel[22]......	16
Tabela 4: Resumo classificadores apresentados [39]......	24
Tabela 5: Requisitos funcionais e suas prioridades.	28
Tabela 6: Requisitos de pesquisa e suas prioridades.	28
Tabela 7: Requisitos não funcionais e suas prioridades.....	28
Tabela 8: Requisitos de interface externa e suas prioridades.....	29
Tabela 9: Valores do <i>P value</i> [72]......	38
Tabela 10: Resultados das características de Pz-Oz.....	40
Tabela 11: Resultados das características de Fpz-Cz.	40
Tabela 12: Características Mulheres Pz-Oz.....	43
Tabela 13: Características Homens Pz-Oz.	43
Tabela 14: Características Mulheres Fpz-Cz.	43
Tabela 15: Características Homens Fpz-Cz.	43
Tabela 16: Idade maior.....	45
Tabela 17: Idade menor.	45
Tabela 18: Dados mulher elétrodo F3.	46
Tabela 19: Dados homem elétrodo F3.	46
Tabela 20: Dados elétrodo F3.....	47
Tabela 21: Dados mulher elétrodo F4.	49
Tabela 22: Dados homem elétrodo F4.	49
Tabela 23: Dados elétrodo F4.....	49
Tabela 24: Dados mulher elétrodo O1.	50
Tabela 25: Dados homem elétrodo O1.	50
Tabela 26: Dados elétrodo O1.....	51
Tabela 27: Dados mulher elétrodo O2.	52
Tabela 28: Dados homem elétrodo O2.	52
Tabela 29: Dados elétrodo O2.....	53
Tabela 30: Elétrodo O1.	58
Tabela 31: Elétrodo O2.	58
Tabela 32: Elétrodo O1.	59
Tabela 33: Elétrodo O2.	59
Tabela 34: Elétrodo O1.	59
Tabela 35: Elétrodo O2.	59
Tabela 36: Resultados do classificador bayesiano.	63
Tabela 37: Resultados da toolbox da rede neuronal para a rede apresentada.....	64
Tabela 38: Erro (%) obtido para os diferentes valores de K.....	65
Tabela 39: Resultado do classificador K-NN para os diferentes valores de K.....	66

Capítulo 1

Introdução

Neste capítulo é feita referência ao que foi proposto para este estágio, toda a análise necessária para o seu desenvolvimento e ainda um breve resumo do que é exposto neste relatório.

Este capítulo encontra-se dividido em três subsecções, começando pela motivação, passando pelos objetivos propostos e terminando com a descrição das diferentes fases deste estágio.

1.1 Motivação

Existem vários problemas relacionados com o sono, problemas esses que tanto se verificam de dia como de noite. Neste sentido, a deteção precoce do estado de sono pode evitar ocorrências indesejáveis, tais como acidentes de viação e também acidentes fabris, uma vez que estes estão muitas vezes relacionados com o trabalho por turnos.

De acordo com um estudo recente da união europeia [1], baseado numa amostra de 12.434 condutores de automóvel, verificou-se que o sono é responsável por 167 (7%) dos acidentes de viação. Sendo que nesses 7% temos o seguinte resultado: em 13,2% dos casos, pelo menos um dos ocupantes do veículo precisou de receber cuidados hospitalares e 3,6% dos casos resultam, em pelo menos, uma morte. Ainda segundo este mesmo estudo, as principais razões de uma pessoa adormecer ao volante derivam: da má qualidade do sono na noite anterior (cerca de 42,5% dos inquiridos); doenças do sono (34,1%); do facto de uma pessoa se sentir adoentada (18,6%) e de períodos longos de condução (16,2%).

É inevitável concluirmos que é necessário progredir neste campo, nomeadamente através do desenvolvimento de metodologias ubíquas capazes de detetar estados de sono e enviar alertas, o que permitirá prevenir a ocorrência de acidentes. Para isso, serão analisados neste estágio sinais de encefalograma (EEG), que possuem características que são dependentes do estado de vigília. Essas características são extraídas do domínio do tempo e da frequência e posteriormente classificadas.

1.2 Objetivos

O objetivo central deste estágio foi o desenvolvimento de uma aplicação para dispositivos Android, que permitiu detetar e avisar a ocorrência de estados de pré-sono. Em termos de *hardware* o sistema desenvolvido assenta sobre o equipamento portátil *Emotiv EEG neuroheadset* (doravante denominado simplesmente por *Emotiv*) que efetua aquisições de sinais de EEG. Os sinais adquiridos serão processados e classificados usando um dispositivo móvel Asus Memo Pad 7. Em suma, assim que um utilizador entre num estado de pré-sono é alertado pelo dispositivo Android através de um sinal sonoro e/ou vibratório, podendo assim o utilizador tomar uma opção relativamente ao seu estado presente.

1.3 Fases do estágio

As diferentes fases deste estágio e a sua calendarização encontram-se descritas no cronograma apresentado no Anexo B.

O primeiro passo deste estágio passou por um estudo sobre a Neurofisiologia do sono para perceber o que é o sono e como é analisado, assim como as fontes de informação utilizadas pelos clínicos para o analisar (Polissonografia¹). Neste último, o estudo incidiu mais sobre eletroencefalograma (EEG), uma vez que é uma das fontes de informação mais relevantes para a classificação de estados de sono.

Como o output desejado são os sinais de EEG, para isso, foi elaborado código java para obtenção desses dados do *Emotiv* (14 elétrodos). Posteriormente, foram feitos estudos e análises baseados numa base de dados disponível na Internet e em dados recolhidos na Unidade de Monitorização em Epilepsia e Sono (UMES) do Centro Hospitalar e Universitário de Coimbra (CHUC). Estes estudos visaram a identificação dos melhores elétrodos, bem como das melhores características do EEG e dos classificadores mais apropriados.

Num terceiro momento, e com base nas análises anteriores, foram implementados no dispositivo móvel para funcionamento em tempo-real: a extração das melhores características, extraídas dos elétrodos mais apropriados; e os melhores classificadores.

¹ Chamado também exame do sono, é resultante da análise de três exames principais: eletroencefalograma (EEG), eletro-oculograma (EOG) e eletromiograma sub-mentoniano (EMG)[2].

Capítulo 2

Estado da Arte

Neste capítulo é elaborado um estudo sobre as técnicas e as metodologias já existentes e com interesse para este estágio. É feita uma apresentação e uma introdução às técnicas já existentes, bem como o estudo das características do sinal de EEG e das metodologias para classificação de sinais mais usadas.

Serão abordados os dois principais temas deste projeto: as modalidades já existentes que fazem essa análise assim como as informações que advêm dos sinais. Inicialmente, iremos falar do sono e de todas as suas fases. De seguida, apresentaremos os principais exames clínicos para detalhadamente descrever todos os seus estados e os momentos em que ocorrem.

2.1 Classificação do sono

O sono é caracterizado, segundo vários estudos e ideologias, por um estado de repouso do corpo e uma alteração do estado da consciência. O sono está dividido em dois estados fundamentais: o estado NREM², ou movimento não rápido dos olhos; e o estado REM³, ou movimento rápido dos olhos. A título de curiosidade é no estado REM que ocorrem os sonhos. Podemos dizer que estes estados estão classificados de maneira a entender o ciclo do sono de um indivíduo, assim como a caracterização e as ações a eles associadas.

O sono NREM [3] pode ser classificado em 4 sub-estados, sendo que os estados 3 e 4 são muito semelhantes e caracterizam-se muitas vezes como um mesmo estado. A caracterização dos diferentes estados encontra-se descrita na Tabela 1.

Tabela 1: Características do sono NREM.

	Caracterização	Duração (Aproximada)
Estado 1	Sensação de sonolência	5 minutos
Estado 2	Caracteriza-se por a pessoa se encontrar a dormir, porém não profundamente.	5 a 15 minutos
Estado 3/ Estado 4	Sono profundo	40 minutos

É de salientar que o presente trabalho pretende detetar o “Estado 1”. Durante as várias horas, o sono é um processo cíclico que atravessa as diferentes fases, como representa a figura 3.

² NREM do inglês Non rapid eye movement (Movimento Não Rápido dos Olhos).

³ REM do inglês Rapid eye Movement (Movimento Rápido dos Olhos).

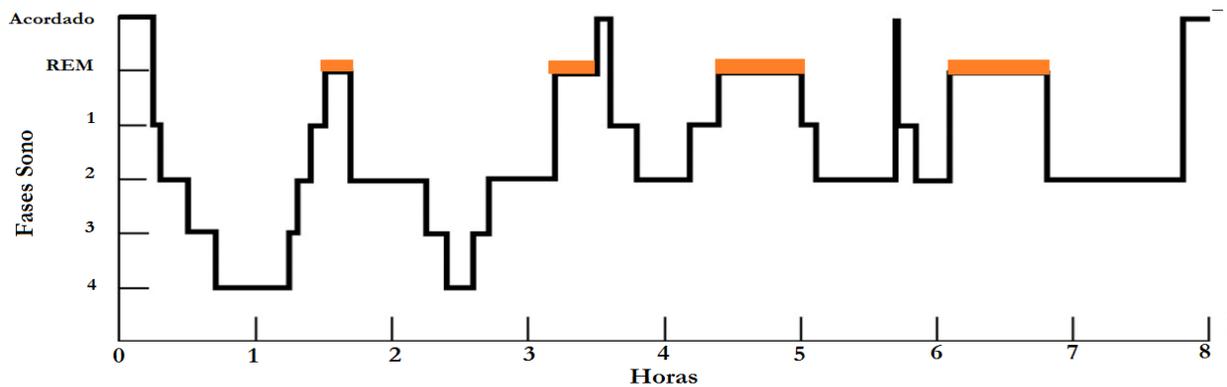


Figura 1: Ciclos dos vários estados do sono (adaptado de [4]).

Como pode verificar-se, os ciclos da Figura 3 contemplam os vários estados do sono sendo que do estado 4 se volta ao estado 2, para depois entrar num estado REM. Verifica-se também que existem fases de movimentos oculares rápidos (REM) durante todo o período de sono e que estas antecedem a fase de sono ligeiro (Estado 1).

Para poder classificar-se clinicamente estes estados, é efetuado um exame de seu nome polissonografia que usa vários tipos de informação para conseguir classificar corretamente o estado atual de um indivíduo num determinado instante. É através deste exame que os clínicos detetam os problemas que advêm do sono, como a apneia, a narcolépsia, a insónia, entre outros. A duração e a ocorrência dos diferentes estados podem variar consoante a idade do indivíduo.

Existem outras técnicas, fora do âmbito clínico, para detecção do estado de sonolência, sendo que essas apenas caracterizam a fase 1, o que vai de encontro ao pretendido neste estágio. Essas técnicas utilizam métodos de detecção através da análise do movimento dos olhos.

2.2 Outras abordagens para detecção de sonolência

Existem nos dias de hoje várias maneiras de poder efetuar um estudo/classificação relativamente ao estado do sono ou a um dos estados específico do sono. Para isso, efetuou-se um estudo em várias áreas por forma a perceber quais as técnicas utilizadas para essa classificação assim como as vantagens e desvantagens de cada um.

2.2.1 Polissonografia

Para uma caracterização clínica dos estados do sono é realizado o exame de polissonografia. Este exame utiliza informação da atividade cerebral medida através do EEG, da atividade ocular medida através do electro-oculografia (EOG) e da atividade muscular medida através de electro-miografia

(EMG). É através desta informação que os clínicos descrevem os estados em que se encontra um determinado indivíduo durante o sono.

Na Tabela 2 são representadas as amplitudes, assim como as frequências assumidas pelos referidos sinais fisiológicos.

Tabela 2: Variáveis eletrofisiológicas com a frequências e amplitudes [5].

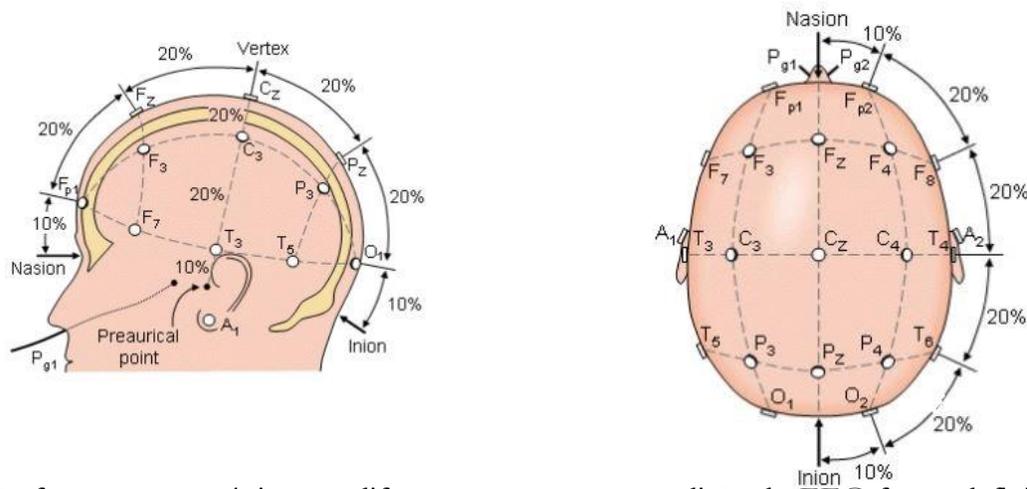
	Amplitude (μV)	Frequência (Hz)
Eletroencefalograma (EEG)	5 – 300	DC-150
Electromiograma (EMG)	100 – 5 000	DC – 1 000
Electroculograma (EOG)	50 – 3 500	DC -50

Como pode ver-se na tabela, a maior parte dos eventos elétricos tem amplitudes ou níveis muito abaixo de 1V e frequências até 1kHz.

2.2.2 Eletroencefalograma EEG

O eletroencefalograma (EEG) não invasivo (Scalp-EEG) regista a atividade cerebral através de eléctodos afixados no coro cabeludo. O primeiro eletroencefalograma [6] realizado a um ser humano foi feito em 1924 por Hans Berger, formado em medicina pela Universidade de Jena. Ele caracterizou as ondas α e β e cunhou o termo "eletroencefalograma".

De uma forma genérica, o EEG é gerado por populações de neurónios que transmitem informação entre eles através de impulsos elétricos. A combinação dos diferentes impulsos é captada pelos eléctodos sobre a forma de uma diferença de potencial entre pares de eléctrodo.



catalogada com duas letras ou uma letra e um número. As letras discriminam o lóbulo cerebral onde o eléctrodo está posicionado, por exemplo: C = central; P = parietal; F = frontal; Fp = frontal polar; O = occipital; T= temporal.

Como é perceptível na Figura 2, a paridade dos números descreve o hemisfério. Os eléctrodos do hemisfério direito são descritos por números pares, enquanto que os eléctrodos do hemisfério esquerdo são descritos por números ímpares.

Não deixa de ser importante a montagem escolhida para a apresentação e processamento do EEG. A montagem pode ser bipolar ou unipolar, como representado nas Figuras 3 e 4. Numa montagem unipolar considera-se simplesmente a diferença de potencial entre um determinado eléctrodo e um eléctrodo neutro comum. Por sua vez, uma montagem bipolar considera relações entre regiões cerebrais.

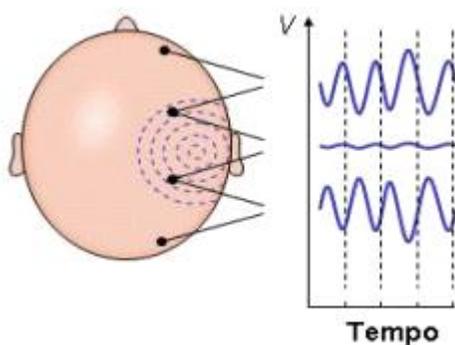


Figura 3: Medida Bipolar [7].

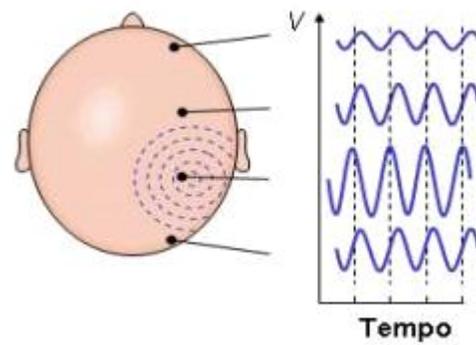


Figura 4: Medida unipolar [7].

Para se poder proceder à detecção e classificação dos vários estados do sono pelo qual o indivíduo passou é feita, normalmente, uma análise do domínio da frequência onde se divide a atividade registrada pelo EEG em 5 bandas de frequência [9], são elas as seguintes:

- Delta (δ) de 0.5 – 4Hz
- Theta (θ) de 4 – 8Hz
- Alpha (α) de 8 – 13Hz
- Beta (β) de 13 – 30Hz
- Gamma (γ) valores > 31Hz.

Assim, é através da análise de características observadas nas diversas bandas de frequência que é possível chegar à conclusão sobre os vários estados de sono pelos quais o indivíduo passou.

O estado 1 é caracterizado por duas assinaturas no sinal de EEG. A primeira é determinada por ondas de baixa intensidade 3-7Hz, sendo necessário efetuar uma análise nas bandas Delta e Theta para a sua detecção [9]. A segunda assinatura é caracterizada pela transição de ondas alfa, com uma frequência de 8-13 Hz (comum no estado desperto), para ondas Theta, com uma frequência de 4-7

Hz [10]. No entanto há a ressaltar que relativamente à potência total do sinal de EEG um acréscimo da atividade nas bandas de baixa frequência como é a banda Teta, resulta num decréscimo da atividade verificada nas bandas de alta frequência (Beta e Gamma) e vice-versa. Deste modo neste estágio, para deteção do estado 1, não se considerou somente a atividade nas bandas de baixa frequência, mas a atividade em todas as bandas.

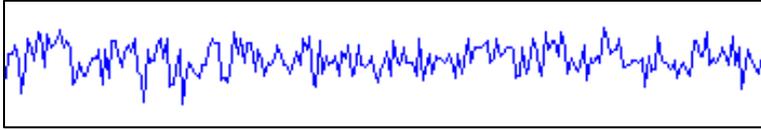


Figura 5: Imagem EEG estado 1 [9].

2.2.3 Análise dos movimentos dos olhos (*Eye tracking technology*)

A técnica do *Eye Tracking* consiste na análise dos movimentos dos olhos. Essa análise permite saber para onde a pessoa se encontra a olhar num determinado momento e analisar a sequência em que os olhos estão a mudar de direção. Através do *Eye Tracking* [46] é elaborada uma leitura do movimento de um olho em relação à cabeça.

Na maioria dos sistemas de *Eye Tracking* [58] comerciais, o método de avaliação consiste em medir o ponto de relação entre “*corneal-reflection/pupil-centre*” [59] como podemos ver na Figura 6.

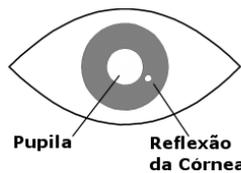


Figura 6: Monotorização da câmara de leitura de infravermelhos.

Desta forma, a partir do momento em que se identifica a pupila e a reflexão da córnea [59], são efetuados cálculos trigonométricos que permitem obter o valor correspondente à relação entre ambos e a sua posição, como ilustra a Figura 7.



Figura 7: Várias posições da câmara por forma a perceber a percepção da pupila em relação à reflexão da córnea [60].

Todos os processos que envolvem a análise baseada em vídeo *Eye Tracking* requerem ajustes a cada utilizador devido às particularidades de cada ser humano. Para esse efeito, é realizada uma calibração que consiste na emissão de um ponto num ecrã e assim o sistema regista *corneal-reflection/pupil-centre*

correspondente a um par de coordenadas de calibração. Isto é repetido várias vezes para que a calibração seja precisa em todo o ecrã [59].

Nos dias de hoje o *Eye Tracking* é muito utilizado para a web, uma vez que através deste sistema pode rapidamente verificar-se o foco das pessoas nas páginas web e assim otimizar as mesmas. Outro dos campos onde o *Eye Tracking* tem bastante relevo é na detecção do sono em meios de transporte, já existindo no mercado um software como o apresentado na Figura 8, que permite a detecção de sonolência e distração de um condutor.



Figura 8: Detecção de sonolência através da análise de *Eye Tracking* (Software Drive State Eléctrodo [57]).

Relativamente aos dispositivos com o *eye tracking*, os mesmos podem ser muito eficazes, sendo que o seu funcionamento é a diferente daqueles baseados em EEG [38].

2.2.4 Variabilidade da frequência cardíaca (HRV)

A variabilidade da frequência cardíaca (HRV) quantifica a variação no intervalo de tempo entre batimentos cardíacos (intervalos RR) e tem sido usada como uma ferramenta de avaliação simples e não-invasiva dos impulsos autonómicos [47,48]. Em geral, a HRV é facilmente calculada e pode ser utilizada como indicador das respostas do sistema nervoso autónomo (ANS), de onde advêm dados como os relativos ao stress, à sonolência, entre outros fatores relacionados, pois o ANS é influenciado pelo sistema nervoso simpático e parassimpático [61]. A HRV é normalmente quantificada através do uso de um eletrocardiograma (ECG) [63]. O ECG tem uma representação como ilustra a Figura 9:

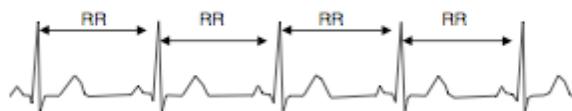


Figura 9: Representação de um eletrocardiograma[64].

No domínio da frequência podem extrair-se características do ECG, tais como: potência associada às muito baixas frequências (VLF: 0.003 – 0.04 Hz), às baixas frequências (LF: 0.04 – 0.15 Hz) e às altas frequências (HF: 0.15 – 0.4 Hz) [61]. Estas medições de frequência são utilizadas para quantificar a atividade do sistema nervoso. Focando apenas o HRV para análise de detecção de estados de sonolência, segundo o estudo [62], existe uma grande relação entre a divisão LF/HF e o estado de sonolência.

Em [61] foi feito um estudo de classificação usando máquinas de vetor de suporte (SVM) e usando características do ECG. Foram reportados sensibilidades e especificidades de 95% usando características extraídas da transformada de Wavelet do sinal de ECG. Em contrapartida, o desempenho usando o rácio LF / HF levou a valores de sensibilidade e especificidade de 62,5% e 75%, respetivamente [61].

Hoje em dia já existem equipamentos que efetuam análise de ECG, por exemplo, alguns modelos da marca Toyota [65] trazem no volante elétrodos que analisam os dados e a cada anomalia emitem um sinal ou produzem uma ação. Este sistema apenas monitoriza arritmias assim como ataques cardíacos. Existem também já outros estudos nos quais a captação dos sinais é feita nos assentos dos veículos [66].

2.2.5 Acelerómetros em dispositivos móveis

Os acelerómetros são dispositivos que podem encontrar-se em vários dispositivos de controlo tais como os *smartphones*, sendo utilizados para complementar ou interagir com algumas funcionalidades dos mesmos. Os acelerómetros [56] consistem num sistema que deteta os movimentos (direita, esquerda, cima, baixo, etc) efetuados pelo telemóvel, podendo assim através da análise no telemóvel detetar os mesmos e, por sua vez, caracterizar o sono. Na verdade já existem aplicações para *smartphones* que utilizam os acelerómetros para efetuar a análise do sono durante um período de tempo, entre elas:

- <http://www.sleepcycle.com/>
- <https://play.google.com/store/apps/details?id=com.urbandroid.sleep>

Existem vários problemas associados à detecção do sono através desta análise, pois a mesma só pode ser efetuada com uma pessoa no local onde se encontra a dormir e o dispositivo móvel tem de encontrar-se sempre próximo do mesmo local.

Esta abordagem pode levar a que não se obtenha uma resposta válida, vejamos o seguinte exemplo: no caso de o dispositivo estar numa almofada ou no colchão (ele tem de estar em contacto com o sítio onde o indivíduo dorme), pode existir um movimento que nada tenha que ver com o sono (por exemplo, apagar a luz), nesse caso, a aplicação falha redondamente nos dados que apresenta. Depois dessa verificação, ficámos com a opinião de que não é uma mais-valia o estudo destas aplicações.

2.3 Características do EEG

A extração de características tem uma grande importância relativamente ao desempenho de um classificador, sendo que uma seleção antecipada das melhores características do problema é fundamental para a obtenção de um classificador eficiente. Existem dois domínios principais: o do tempo e o da frequência.

Existem vários tipos de características, porém aqui apenas são abordadas as principais relativamente aos sinais EEG.

2.3.1 Características do domínio do tempo

Da análise dos sinais no domínio do tempo [15] podem retirar-se características derivadas da amplitude do EEG, tais como: as medidas estatísticas, a energia.

2.3.1.1 Medidas Estatísticas

As medidas estatísticas consideradas foram os momentos de 1ª a 4ª ordem, isto é a média, a variância, a assimetria e a curtose. O valor da média ($\bar{X}[n]$) é calculado pela soma de N amostras contidas em uma determinada janela de sinal que aqui é descrita pelo índice n . No final essa soma é dividida pelo número de amostras.

$$\bar{X}[n] = \frac{1}{N} \sum_{i=1}^N X_n[i] \quad (1)$$

Relativamente à variância ($\sigma^2[n]$), para uma janela de sinal de índice n , ela é descrita por:

$$\sigma^2[n] = \frac{1}{N} \sum_{i=1}^N (X_n[i] - \bar{X}[n])^2 \quad (2)$$

Onde $\bar{X}[n]$ é a média da porção de sinal calculada segundo a equação (1).

O cálculo da assimetria ($\chi[n]$) [44] permite medir o grau de assimetria, que é tanto mais acentuado quanto mais elevados são os valores absolutos do coeficiente de assimetria.

$$\chi[n] = \frac{\frac{1}{N} \sum_{i=1}^N (X_n[i] - \bar{X}[n])^2}{\left(\sqrt{\frac{1}{N} \sum_{i=1}^N (X_n[i] - \bar{X}[n])^2} \right)^3} \quad (3)$$

- $\chi[n] = 0$: distribuição simétrica

- $\chi[n] > 0$: distribuição assimétrica positiva
- $\chi[n] < 0$: distribuição assimétrica negativa

O cálculo da curtose ($\kappa[n]$) [44] quantifica o grau de achatamento de uma distribuição em relação a uma distribuição normal (Gaussiana).

$$\kappa[n] = \frac{\frac{1}{N} \sum_{i=1}^N (X_n[i] - \bar{X}[n])^4}{\left(\frac{1}{N} \sum_{i=1}^N (X_n[i] - \bar{X}[n])^2\right)^2} \quad (4)$$

Através do resultado de $\kappa[n]$ podemos inferir relativamente ao tipo de achatamento da distribuição, como se mostra na Figura 10, sendo que o índice da curtose é dado por:

- Se $\kappa[n] > 3$ A distribuição é leptocúrtica.
- Se $\kappa[n] = 3$ A distribuição é mesocúrtica.
- Se $\kappa[n] < 3$ A distribuição é platicúrtica.

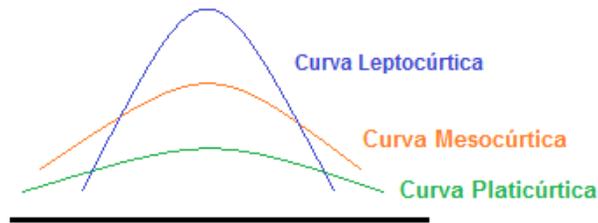


Figura 10: Curvas relativas ao resultado do cálculo da curtose.

2.3.1.2 Energia

A energia do sinal ($E[n]$) para uma determinada janela de sinal com N amostras é dada por:

$$E[n] = \frac{1}{N} \sum_{i=1}^N X_n^2 \quad (5)$$

2.3.2 Características do domínio da frequência

Neste trabalho a análise na frequência de sinais discretos é baseada no algoritmo da transformada rápida de fourier (FFT), descrito na sub-seção 3.5.2.

No caso do EEG as características mais populares no domínio da frequência [15] são as potências relativas nas diversas bandas. Existem muitas outras que poderiam ser extraídas mas para este estudo foram consideradas para além das potências relativas os coeficientes Hjorth.

2.3.2.1 Potências Relativas

As potências relativas são obtidas através do cálculo da área definida pelo espectro de magnitude para uma determinada banda, dividida pela área total obtida para toda a banda útil. Sejam os valores X_1, X_2, \dots, X_n os valores do espectro de magnitude de um sinal $x[n]$ amostrado a uma frequência f_s , e P o valor da área total para a banda útil $[0\text{Hz}, f_s/2 \text{ Hz}]$, as potências relativas nas diversas bandas são calculadas pelas fórmulas descritas abaixo.

Para se obter o valor referente à banda Delta (0.5Hz – 4Hz) temos:

$$\delta_r[n] = \frac{1}{P} \sum_{k=\lfloor 0,5\text{Hz} \cdot \frac{N}{f_s} \rfloor}^{\lfloor 4\text{Hz} \cdot \frac{N}{f_s} \rfloor} |X_n[k]|^2 \quad (6)$$

Para se obter o valor referente à banda Theta (4Hz – 8hz) temos:

$$\vartheta_r[n] = \frac{1}{P} \sum_{k=\lfloor 4\text{Hz} \cdot \frac{N}{f_s} \rfloor}^{\lfloor 8\text{Hz} \cdot \frac{N}{f_s} \rfloor} |X_n[k]|^2 \quad (7)$$

Para se obter o valor referente à banda Alpha (8Hz – 13hz) temos:

$$\alpha_r[n] = \frac{1}{P} \sum_{k=\lfloor 8\text{Hz} \cdot \frac{N}{f_s} \rfloor}^{\lfloor 13\text{Hz} \cdot \frac{N}{f_s} \rfloor} |X_n[k]|^2 \quad (8)$$

Para se obter o valor referente à banda Beta (13Hz – 30hz) temos:

$$\beta_r[n] = \frac{1}{P} \sum_{k=\lfloor 13\text{Hz} \cdot \frac{N}{f_s} \rfloor}^{\lfloor 30\text{Hz} \cdot \frac{N}{f_s} \rfloor} |X_n[k]|^2 \quad (9)$$

Para se obter o valor referente à banda Gamma ($>30\text{Hz}$) temos:

$$\gamma_r[n] = \frac{1}{P} \sum_{k=\lfloor 30\text{Hz} \cdot \frac{N}{f_s} \rfloor}^{\lfloor f_s/2 \rfloor} |X_n[k]|^2 \quad (10)$$

De referir que as potências relativas nas diversas bandas são as características que estão melhor documentadas em análise de estados de sonolência.

2.3.2.2 Coeficientes Hjorth

Os parâmetros introduzidos por Hjort (1970)[20] corresponderam às primeiras tentativas para descrever quantitativamente o EEG em parâmetros: atividade (A); mobilidade (M) e de complexidade (C).

A atividade é a simples variância ou potência média [42]. No domínio da frequência [43], os valores referentes a mobilidade e complexidade de Hjorth podem ser estimados a partir do segundo e quartos momentos estatísticos do espectro de potência do sinal ($X_n[K]$), respectivamente [43]:

Mobilidade de Hjorth:

$$HM[n] = \frac{1}{P} \sum_{K=1}^{N/2} |X_n[K]|^2 K^2 \quad (11)$$

Complexidade de Hjorth:

$$HC[n] = \frac{1}{P} \sum_{K=1}^{N/2} |X_n[K]|^2 K^4 \quad (12)$$

Onde P é a potência total associada ao sinal em causa.

2.3.2.3 Resumo

Relativamente às características apresentadas anteriormente, as mesmas são usadas em vários estudos de análise de sono. Segundo o estudo [76] as características como a média, a assimetria e a curtose estão relacionadas com a forma do sinal EEG. Como este é um sinal não determinístico e não-estacionário, é muito difícil obter-se informação dessas características.

Segundo um outro estudo [77] verifica-se uma outra análise entre os coeficientes Hjorth e as potências relativas, no qual estas são mais discriminativas na análise dos vários estados do sono. Segundo este estudo as potências relativas obtêm um resultado de 75% de acertos, mais 16% do que em relação aos coeficientes Hjorth.

2.4 Classificadores

A classificação implica a existência de um vetor de características e de uma saída desejada (target) para treino e validação. Os parâmetros do classificador são determinados em função do conjunto de treino, sendo a elaboração deste determinante para o processo de classificação.

Foi elaborado um estudo de diversos algoritmos capazes de solucionar o nosso problema e apresentados a seguir, sendo certo que apenas foi implementado o algoritmo que melhores resultados obteve neste campo do sinal EEG.

2.4.1 Máquina de vetor de suporte (SVM)

A base teórica do algoritmo SVM foi proposta por Vladimir N. Vapnik [21]. Este método de reconhecimento de padrões tem como base a definição de um hiperplano que maximiza a separação entre padrões pertencentes à classe positiva (+1) e à classe negativa (-1).

SVM Linear

Segundo o algoritmo SVM [22] temos um conjunto de treino denominado por $\{x_i, y_i\}_{i=1}$, em que os valores do x_i são as entradas e $x_i \in R^n$ e as respectivas saídas são $y_i \in \{-1, +1\}$ [22]. O SVM tem como função primária a classificação binária, sendo que para isso é criada uma superfície linear $f(x)=0$, que é apresentada por[22]:

$$w^t \cdot \varphi(x) + b = 0 \quad (13)$$

- w é o vetor dos pesos;
- φ mapeamento realizado num determinado espaço(espaço de características);
- b o deslocamento do hiperplano a partir da origem.

Aquando de um processo de treino, para se indicar se a classificação do treino foi correta, utiliza-se a saída desejada y_i e a saída obtida $f(x_i)$, efectuando o produto entre ambos, como é apresentado[22]:

$$y_i [w^t \cdot \varphi(x_i) + b] \geq 1 + \xi_i \text{ com } \xi_i \geq 0 \quad (14)$$

O processo de treino consiste na determinação de w e b que minimizam a função de custo $J(W, \xi)$. O objetivo principal das SVM é a determinação de um hiperplano ótimo, de forma a conseguir maximizar as margens de separação, dada por [22]:

$$M = \frac{2}{\|w\|^2} \quad (15)$$

Para se conseguir maximizar a margem é necessário minimizar o vetor de pesos $\|w\|^2$, sendo certo que o mesmo é minimizado pelo primeiro termo da função $J(w, \xi)$.

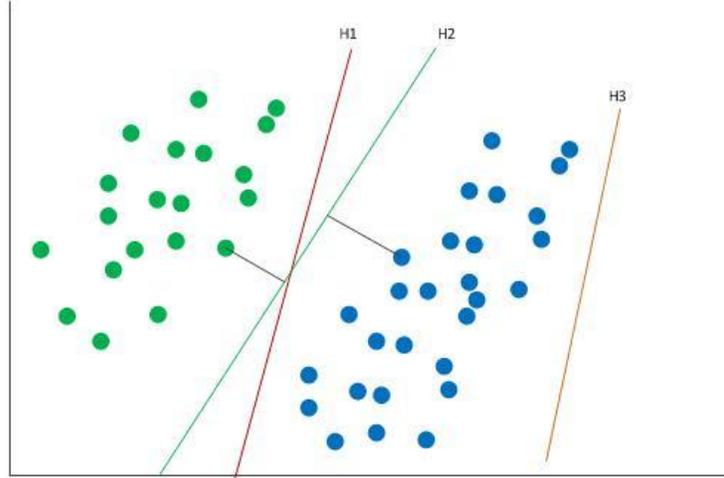


Figura 11: Hiperplano numa rede SVM [23]

Como é apresentado na Figura 11, o melhor hiperplano é o que contém uma margem maior, como demonstra a linha H2.

Podemos assim definir um problema primal [22]:

$$\min_{w,b,\xi} J_p(w, \xi) = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^N \xi_i \quad \begin{cases} y_i [w^t \cdot \varphi(x_i) + b] \geq 1 - \xi_i \\ \xi_i \geq 0, \quad i = 1, \dots, N \end{cases} \quad (16)$$

Aplicando a função Lagrangiana [24] vamos transformar um problema primal em dual, por forma a que seja mais simples de resolver o problema de otimização. As derivadas são igualadas a zero, permitindo minimizar o Lagrangiano em relação aos parâmetros reais, sendo então dada por [24]:

$$\max_{\alpha} J_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i x_j) \quad \begin{cases} \sum_{i=1}^N \alpha_i y_i = 0 \\ 0 \leq \alpha_i \leq C, \quad i = 1, \dots, N \end{cases} \quad (17)$$

Desta equação podemos verificar algumas restrições, nomeadamente, o facto de α ser limitado pelo parâmetro C .

SVM não linear

A função $K(x_i x_j)$ [22] é chamada de função de *Kernel*. Existem várias funções de *Kernel*, como por exemplo as que se encontram descritas na Tabela 3:

Tabela 3 Várias funções de Kernel[22].

Kernel	Expressão	Parâmetro
Linear	$x_i^t \cdot x_j$	
Polinomial	$(x_i^t \cdot x_j + a)^b$	a, b
Sigmóide	$\tanh(\beta_0 x_i^t \cdot x_j + \beta_1)$	β_0, β_1
RBF	$\exp\left(-\frac{ x_i - x_j ^2}{\sigma^2}\right)$	σ

É através das funções de Kernel[22] que podemos resolver problemas não lineares por SVM, uma vez que a superfície de separação é linear apenas no espaço de características e não no espaço de entradas.

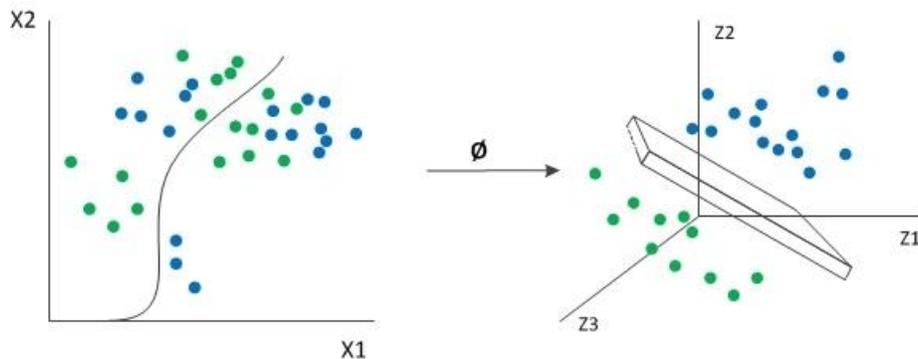


Figura 12: Exemplo de uma solução de um problema não linear

Considerações finais

Na obtenção dos valores de w e b do SVM [37], para cada novo padrão x_j , temos a seguinte equação[37]:

$$\begin{aligned}
 f(x_j) &= w \cdot x_j + b \\
 &= \sum_{i=1}^n \lambda_i y_i (x_i x_j) + b
 \end{aligned} \tag{18}$$

O produto interno (multiplicação de x_i e x_j) pode ser obtido usando as funções de *Kernel*. E, ainda, no produto interno essas mesmas funções permitem calcular $k(x_i, x_j) = \phi^T(x_i) \phi(x_j)$ [37].

Quando é *Kernel* linear [37], temos:

$$k(x_i, x_j) = x_i \cdot x_j \quad (19)$$

Isto é, a operação de produto interno é feito sem transformação. Na utilização de outras funções de *Kernel* (por exemplo Radial Basis Function (RBF)) as superfícies de separação deixam de ser hiperplanos [37]. Logo, a classificação irá ser realizada através da seguinte equação [37]:

$$\text{sign} \left(\sum_{i=1}^n \lambda_i y_i k(x_i, x_j) + b \right) \quad (20)$$

Portanto, caso o ponto de teste esteja corretamente classificado, temos: se a saída for -1, o ponto de teste encontra-se na região -1; se a saída for +1, a saída encontra-se na região +1.

2.4.2 Redes neuronais artificiais

Os primeiros modelos de redes neuronais artificiais (Artificial Neural Network (ANN, RNA ou simplesmente NN)) [25] foram elaborados por McCulloch e Pitts [26]. Essas redes eram baseadas na compreensão da neurologia, daí as redes assemelham-se muito à estrutura do neurónio humano. Através da Figura 13, é possível perceber o funcionamento de uma ANN [27] e de todas as variáveis e pontos apresentados, que consistem nos parâmetros de entrada, assim como os de saída, descritos a seguir:

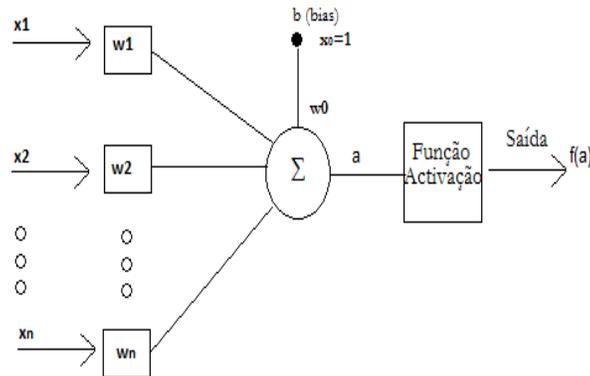


Figura 13: Exemplo de uma rede ANN [28].

Descrição:

- x_n são valores de entradas.
- w_n são os pesos associados à entrada.
- b é o valor numérico associado ao neurónio.
- a é dado por $a = \sum_{i=1}^N w_i x_i$.
- Saída é dado por $f(a)$.

O cálculo associado ao neurónio j , que é dado por a_j , é calculado através do valor da entrada multiplicado pelo seu peso, como mostra [28]:

$$a_j = \sum_{i=1}^N x_i w_{ji} \quad (21)$$

É através dos valores resultantes desses cálculos que se obtém o valor de saída dada por uma função sigmoid:

$$f(a_j) = \frac{1}{1 + \exp^{-a_j}} \quad (22)$$

A seguir é apresentada uma ANN, que aprende usando o algoritmo de retropropagação dos erros (backpropagation) [28], uma vez que é o algoritmo de treino mais usado em ANNs e muitos outros são baseados nele.

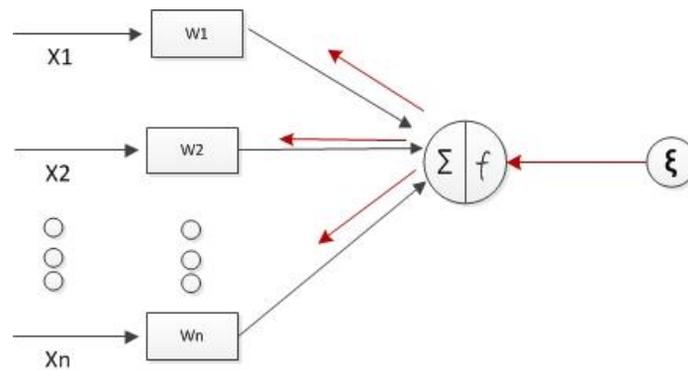


Figura 14: Implementação de retropropagação [29].

Este algoritmo tem como base a minimização do erro numa rede e para isso tem que ir ajustando os pesos de maneira a que esse erro seja mínimo [29]. Entende-se, também, que o algoritmo é supervisionado o que significa que se fornecem exemplos de entradas e de saídas que queremos calcular e, em seguida, é calculado o erro (diferença entre os resultados reais e esperados) [29].

Assim, os neurónios artificiais são organizados em camadas e ao enviar os seus sinais para a saída, é calculado o erro e os erros são retropropagados para trás, como pode ver-se na Figura 14.

Já relativamente à sua implementação, a correção do erro é calculada pela função [30]:

$$\Delta w_{ji} = -\eta \delta_j f(a_i) \quad (23)$$

Onde o valor de Δw_{ji} é o resultado dos ajustes dos pesos entre o neurónio j e o neurónio i da camada anterior, sendo que para isso é necessário saber o valor de saída ($f(a_i)$) do neurónio i , a taxa de erro associada (η), assim como a camada que é dada pelo δ_j , sendo certo que para calcular a camada temos [30]:

$$\delta_j = (Y_j - \hat{Y}_j) f'_i(a_j) \quad (24)$$

Onde o valor de Y_j é o valor esperado e o de \hat{Y}_j é o valor de saída, ambos relativamente ao neurónio j , sendo que na camada escondida vamos ter:

$$\delta_j = f'_j(a_j) \sum_{k=1}^k \delta_k W_{kj} \quad (25)$$

Na camada escondida, o valor de k é o número de neurónios que estão na camada seguinte. Relativamente à taxa de erro de aprendizagem, a mesma pode ser baixa ou alta. Segundo a referência [31] existe os seguintes problema: quando o valor da taxa é elevada pode ficar preso num mínimo local, por outro lado, quando a taxa é baixa a convergência dos pesos é muito lenta para se tornar ótima. Para reduzir esses problemas foi usado o termo α e ΔW_{ji} , tendo então[31]:

$$\Delta W_{ji} = -\eta \delta_j f(a_i) + \alpha \Delta W_{ji}^{Prev} \quad (26)$$

De nota que ΔW_{ji}^{Prev} é o valor de correcção da iteração anterior.

Se erro_presente > erro_anterior * 1.04

$$\eta = \eta * 0.75$$

$$\alpha = 0$$

Senão

$$\eta = \eta * 1.05$$

$$\alpha = 0.95$$

Assim, a minimização da soma quadrada de erros (SSE in inglês) é dada pela função [31]:

$$SSE = \frac{1}{2} \sum_{p=1}^P \sum_{j=1}^N (Y_{pj} - \hat{Y}_{pj})^2 \quad (27)$$

As variáveis Y_{pj} e \hat{Y}_{pj} são, respetivamente, o valor esperado de saída e o valor estimado; o número de registo é dado por j , que varia até N , e o número de neurónios na camada de saída é dada por $p=1, \dots, P$.

2.4.3 Redes Bayesianas

As Redes Bayesianas (Bayesian Networks (BN)) [33] surgiram derivado à utilização da fórmula matemática para o cálculo de probabilidades, de seu nome teoria da probabilidade bayesiana, publicada por Thomas Bayes em 1763 [34]. Esta rede organiza todo o seu conhecimento adquirido em cada área por uma causa efeito. Esta técnica surgiu derivado às dificuldades na apresentação das probabilidades, pois estas não eram muito intuitivas e existiam dificuldades de dedução das mesmas.

O raciocínio Bayesiano [55] foi considerado como um ideal não realizável e, por isso, foram propostas soluções como abordagens heurísticas, lógica difusa e teoria de Dempster & Shaffer. Como pode ver-se na Figura 15, esta rede é feita através de gráficos acíclicos [33] direcionados e na qual a probabilidade associada a cada variável representa um nó do gráficos e os arcos representam a dependência informativa entre as variáveis.

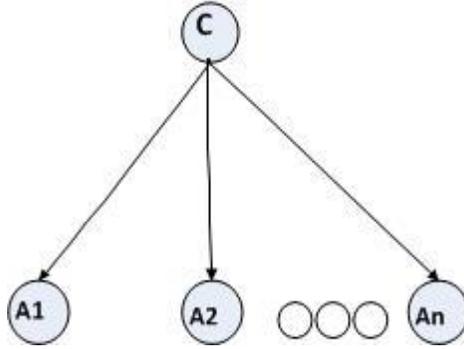


Figura 15: Exemplo de uma rede basyesiana[33].

Uma definição das redes bayesianas é dada por [33] gráficos acíclicos dirigidos e representados por uma distribuição de probabilidade conjunta constituída por um conjunto de variáveis aleatórias, sendo essas variáveis representadas por A_1, A_2, \dots, A_n a que correspondem também os nós. A rede é definida por $B = \langle G, \Theta \rangle$ [33] e a variável G é definida pelos seus nós X_i , sendo que cada nó é independente dos seus nós-descendentes, dado os seus pais em G . A componente relativa ao Θ verifica o conjunto de parâmetros que quantificam a rede e é dado por um parâmetro

$\theta_{X_i|\pi_i} = P_B(X_i|\pi_i)$ [33]. Para cada valor de X_i ou de π_i , o valor de B será único para cada distribuição de probabilidade conjunta, dada por[33]:

$$P_B(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P_B(X_i|\pi_i) = \prod_{i=1}^n \theta_{X_i|\pi_i} \quad (28)$$

Existem alguns problemas nas redes bayesianas [34] no que toca à sua aprendizagem, podendo afirmar-se os seguintes exemplos: dados de treinos, informação prévia e estrutura das redes das quais são apresentadas as topologias dos gráficos.

Os dados de treinos são dados por $\Sigma = \{X_1, \dots, X_n\}$, sendo os parâmetros de $\Theta = (\theta_1, \dots, \theta_n)$, onde os vetores de parâmetros é θ_i e o nó é X_i , considerado também como distribuição condicional do vetor. O log-likelihood [34] dos dados de treino é a soma dos termos de cada um dos nós, tendo assim:

$$\log L(\theta|\Sigma) = \sum_m \sum_n \log P(x_{li}|\pi_i\theta_i) \quad (29)$$

Podemos então dizer que, com o log-likelihood conseguimos maximizar o termo.

2.4.4 K-Vizinhos Mais Próximos

O K-vizinhos mais próximos (K-nearest neighbor (kNN)) é um classificador de fácil entendimento e a sua técnica de classificação também é de fácil implementação. O conjunto de treino é formado por vetores n-dimensionais e cada elemento deste conjunto representa um ponto no espaço n-dimensional [35]. Não é considerado um verdadeiro algoritmo de aprendizagem, uma vez que não tem uma fase de aprendizagem, apenas calcula uma métrica e por isso diz-se que é um *Lazy learning*. Dado um conjunto de treino D [35] descrito por $x=(x',y')$, formado por padrões de entrada (x') e pela respetiva etiqueta (y'), calcula-se a distância entre um determinado padrão z e todos os padrões existentes em D, para depois se obter os K vizinhos mais próximos. Desta forma é possível definir um sub-conjunto de D chamado D_z que engloba os K padrões mais próximos de z [35].

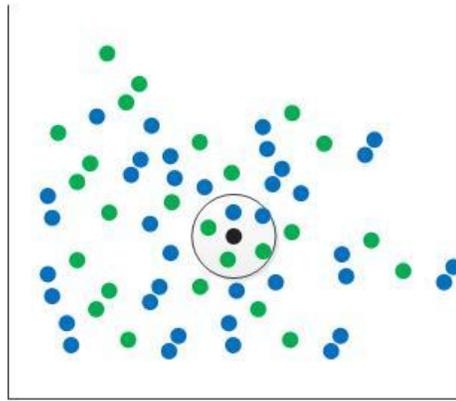


Figura 16: Exemplo de KNN para um K=5.

Depois de ter a lista de vizinhos mais próximos vamos calcular a classe a que z pertence através da análise das classes dos seus vizinhos, onde a classe da maioria irá ditar a classe de z . Matematicamente [35]:

$$y' = \underset{v}{\operatorname{argmax}} \sum_{(x_i, y_i) \in D_z} I(v = Y_i) \quad (30)$$

O valor de v é uma etiqueta da class, Y_i é a etiqueta das classes para os vizinhos mais próximos e a função $I(v = Y_i)$ devolve 1, no caso de $v = Y_i$ ou devolve 0, no caso contrário.

Relativamente à escolha de um valor de K (número de vizinhos) podemos ter dois problemas: a escolha de um K muito pequeno pode levar a uma maior sensibilidade ao ruído; por outro lado, a escolha de um K muito grande pode incluir muitos pontos de outras classes. Assim, é aconselhável fazer primeiro vários testes variando o valor de K e de seguida verificar o valor do erro em dados de teste para obter o melhor valor de K.

2.4.5 Modelos ocultos de Markov

Os Modelos Ocultos de Markov (Hidden Markov Models - HMM) foram descritos pela primeira vez ao final dos anos 60 [53]. Leonard E. Baum e colaboradores publicaram uma série de artigos [51][52] lançando as bases para o formalismo dos HMM. A aplicação desses modelos em reconhecimento de palavras começou a ser utilizada em meados dos anos 70 [53].

O HMM exige a análise de dois processos estocásticos sendo eles [49]:

- Determinar a probabilidade da transição entre estados.
- Observações de saída a cada estado.

São caracterizados por um processo estocástico não visível (daí o nome escondido), mas que pode ser observado através de outro processo estocástico que produz a sequência de observações [54]. Os processos escondidos formam um conjunto de estados ligados onde a transição entre estados ocorre segundo uma determinada probabilidade (autômato finito). Por outro lado, os não escondidos consistem nas saídas ou observações, sendo que cada qual pode ser emitido por estado de acordo com a função densidade.

Dependendo da sua função densidade podemos distinguir várias classes de HMM's, nomeadamente [54]: Discretos; Contínuos; Semi-contínuos.

A maior vantagem do HMM é a sua natureza probabilística, tornando-se assim uma das principais abordagens para reconhecimento de sequências de acontecimentos, tendo-se verificado que se encontram bem adaptados para caracterizar a variabilidade de sinais temporais [54].

Um HMM para observações de símbolos discretos é caracterizado por [54]:

- Um conjunto de estados $N = \{1, 2, 3, \dots, N\}$
- Estado ativo no tempo t denominado por q_t
- Um número M de possíveis observações para os estados, onde os símbolos individuais são apresentados como, $V = \{v_1, v_2, v_3, \dots, v_M\}$
- Uma distribuição de probabilidade de transição entre estados $A = \{a_{ij}\}$, tal que:

$$a_{ij} = P[q_{t+1} = j | q_t = i], \quad 1 \leq i, j \leq N \quad (31)$$

Para casos especiais onde qualquer estado pode alcançar qualquer outro estado em uma simples etapa tem-se que $a_{ij} > 0$ Para todo i, j . Para outros tipos de HMM, pode-se ter $a_{ij} = 0$ para um ou mais pares de (i, j) .

- Uma distribuição de probabilidade de observação $B = \{b_{ij}(k)\}$, onde define a distribuição de símbolos no estado $j, j=1, 2, \dots, N$ tal que:

$$b_j(k) = P[O_t = v_k | q_t = j], \quad 1 \leq j \leq N \quad (32)$$

- Uma matriz inicial $\pi = \{\pi_j\}$, tal que:

$$\pi_j = P[q_1 = j], \quad 1 \leq j \leq N \quad (33)$$

Assim pode-se observar que um HMM requer a definição de N e M , que estão relacionados com a observação de símbolos e com o conjunto de três medidas de probabilidades A, B e π . Por conveniência será utilizada uma noção compacta $\lambda=(A, B, \pi)$ para indicar o conjunto completo dos parâmetros do modelo.

Relativamente aos tipos de modelos ocultos de Markov, estes são apresentados segundo dois tipos gerais sendo eles [35]:

- Modelos sem restrições ou ergóticos;
- Modelos esquerda-direita;

Os modelos sequenciais e paralelos fazem parte dos modelos esquerda-direita. Para esses modelos, a matriz de transição entre estados é triangular superior.

Nos modelos sem restrições (Fig.17), todas as transições são possíveis entre os estados, ou seja nenhum dos valores de a_{ij} é nulo.

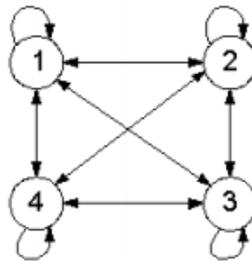


Figura 17: Modelo sem restrições [53].

Os modelos sequenciais (Fig. 18) implementam uma transição em série entre estados, mesmo que seja possível saltar para estados não sequenciais.

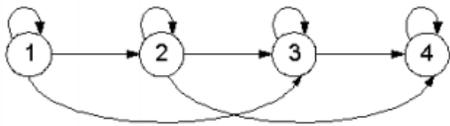


Figura 18: Modelo sequencial [53].

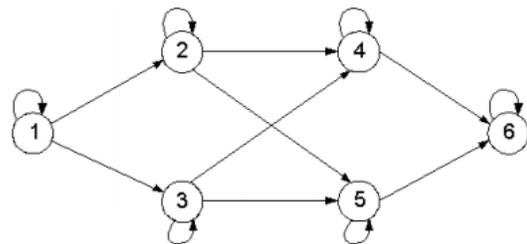


Figura 19: Modelo paralelo [53].

Nos modelos paralelos (Fig. 19) muitos caminhos são possíveis através da rede de Markov, permitindo o acesso aos estados por diferentes caminhos.

Cada um dos estados apresentados nas Figuras 17, 18 e 19, podem ser generalizados por incluir um número de estados arbitrário. A estrutura do modelo e o número de estados escolhidos são fatores fundamentais para a determinação do HMM ótimo [53].

2.4.6 Resumo Classificadores

Resumo dos resultados obtidos pelos classificadores:

Tabela 4: Resumo classificadores apresentados [39].

Classificador	Propriedades
BN	<ul style="list-style-type: none"> • São diagramas que organizam o conhecimento numa dada área através de um mapeamento causa efeito. • Inserção fácil de conhecimento a priori. • Produz limites de decisão lineares.
SVM	<ul style="list-style-type: none"> • Linear e não-linear. • Método binário ou multiclasse. • Determinação de um hiperplano ótimo, de forma a conseguir sempre maximizar as margens de separação.
K-NN	<ul style="list-style-type: none"> • Fácil Implementação. • Multiclasse. • Eficiente com vetores de características de baixa dimensionalidade.
ANN	<ul style="list-style-type: none"> • Classificador muito flexível. • Minimização de um critério de erro. • Multiclasse.
HMM	<ul style="list-style-type: none"> • Baseia-se na probabilidade do anterior. • Garantia de convergência para um ótimo ponto.

Depois do estudo efetuado sobre os classificadores apresentados anteriormente verificámos que o K- vizinho mais próximo é um classificador de pouca confiança, uma vez que tanto pode dar bons, como maus resultados, tudo dependendo do valor atribuído a K. Relativamente aos outros quatro classificadores, qualquer um deles se enquadra muito bem neste projeto. Segundo o estudo apresentado em [36] sobre classificação e reconhecimento de sinais EEG, o algoritmo SVM é o que obtém melhores classificações, dentro de todos os outros algoritmos aqui abordados. No entanto, será feita uma análise utilizando os classificadores aqui apresentados e, dependendo dos resultados, será escolhido aquele que apresentar melhores resultados.

Capítulo 3

Materiais e Métodos

Neste capítulo apresentamos todo o material existente para a realização do estágio e as ferramentas utilizadas para o desenvolvimento de um *software* capaz de detetar eficazmente o estado de sonolência.

Abordamos em primeiro lugar os métodos de extração de características, seguindo-se uma análise da capacidade discriminativa das mesmas e, posteriormente, os algoritmos de classificação considerados para o desenvolvimento deste estágio. As características analisadas foram aquelas que entendemos serem as mais relevantes para o problema em causa, criando assim vetores de características que foram classificados por técnicas de reconhecimento de padrões.

3.1 Hardware de aquisição Emotiv

Para a aquisição dos sinais EEG [18] e dos giroscópios vamos utilizar o *hardware Emotiv EEG neuroheadset* e para o processamento ubíquo dos dados foi utilizado um tablet (Asus Memo Pad) com sistema operativo Android.

O *Emotiv* permite a aquisição de 14 canais de EEG [40] dispostos segundo o sistema internacional 10-20 [8] nas seguintes posições:

AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 e AF4, (como pode observar-se na Figura 20).

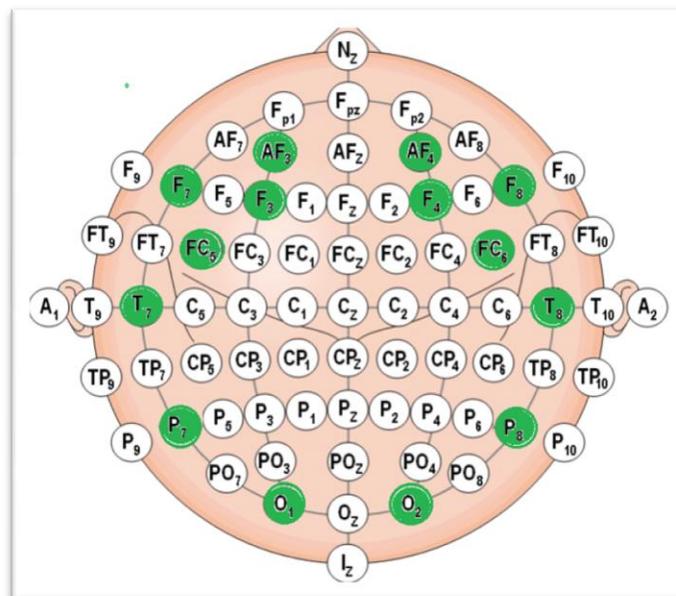


Figura 20: Sistema 10-20 de posicionamento [8]. Os pontos a verde representam os pontos de leitura do *hardware Emotiv*.

O *Emotiv* usa dois elétrodos como referência situados na parte de trás da orelha (o mastoid). Possui ainda os giroscópios que efetuam leituras do movimento da cabeça nos eixos horizontal e vertical. Este *hardware* efetua uma ligação wireless com um dispositivo para conseguir apresentar os sinais medidos pelos elétrodos, sendo que o dispositivo tem como frequência de amostragem 128Hz e um filtro passa-banda (0.2Hz – 45Hz). Contém, ainda, uma bateria com duração para cerca de 12h.

3.2 Transmissão de dados

Neste projeto, o dispositivo móvel Android, tem capacidade para se interligar com um tablet através de um interface *USB On-The-Go* (otg). Para tal, é necessário dispositivos com API nível 13 ou superior. Ainda relativamente ao USB, em Android o *smartphone* pode funcionar como um ponto *host* ou funcionar como *Accessory* [17], isto é, recebe informação ou apenas envia, sendo que no nosso caso apenas recebe a informação enviada pelo *Emotiv*. A programação da aplicação é na vertente de *host*, permitindo utilizar as funções disponíveis para conseguir-se obter a informação [17].

Para a realização das leituras dos dados foi necessário efetuar um estudo acerca da informação que o *Emotiv* envia, sendo que não existia nenhuma API para o efeito. Desta forma foi desenvolvido *software* que permitiu descriptar e verificar que algumas das suas leituras eram sequências de 8 bits (valor bateria, número de pacotes) e que outras leituras eram enviadas como sequências de 14 bits (valores dos elétrodos).

Tivemos em atenção quais os problemas que podiam surgir com a leitura de dados e apresentação dos mesmos em tempo real. Porém, verificámos, através de aplicações já existentes, que o sistema operativo Android conseguia desempenhar devidamente essa função.

3.3 Definição de requisitos

O levantamento de requisitos é fundamental no desenvolvimento de um produto de software, pois permite obter a primeira perceção do que será o nosso produto final, assim como as funcionalidades esperadas.

Inicialmente verificámos as necessidades do utilizador no que respeita à leitura de sinais EEG, podendo assim conseguir tirar melhor partido da aplicação do dispositivo móvel.

A categorização de requisitos foi feita seguindo as recomendações do *Institute of Electrical and Electronics Engineers* (IEEE) [45] que sugere a divisão dos requisitos em vários tipos diferentes, sendo eles: funcionais; relativos a interfaces externas; relativos à performance; relacionados com atributos; e relativos a restrições de *design*. Cada um destes tipos têm ainda sub-tipos que são apresentados mais à frente aquando da apresentação de cada requisito necessário para o nosso projeto.

Todos os requisitos apresentados para o projeto em causa foram elaborados e discutidos com o orientador de forma a englobar todas as necessidades de uma aplicação deste tipo.

3.3.1. Análise de MoSCow

A análise de MosCow [41] divide os requisitos em quatro categorias: *must*, *should*, *could* e *won't*.

- **Must:** É fundamental e obrigatório para o desenvolvimento do projeto que o requisito seja implementado.
- **Should:** É importante que o requisito seja implementado, contudo, por restrições de tempo pode não ser implementado.
- **Could:** Considera-se que o requisito é desejável, porém não necessário. É realizado apenas se os recursos e o tempo permitirem.
- **Won't:** Requisito que se concorda que não seja implementado nesta versão, podendo ser considerado posteriormente.

Estas categorias serão utilizadas no campo de prioridades dos nossos requisitos, podendo assim definir desde logo a prioridade de cada requisito.

3.3.2. Funcionalidades do produto

Este será um produto que irá permitir detetar e avisar a ocorrência de estados de pré-sono (sonolência). Para isso é necessário efetuar uma análise detalhada dos sinais EEG vindos do equipamento *Emotiv*. O utilizador tem acesso aos sinais medidos pelos eléctodos que captam a atividade eléctrica cerebral em diversos pontos do couro cabeludo. Para além da atividade eléctrica cerebral o utilizador tem também acesso à qualidade de contacto entre os diferentes eléctodos e o couro cabeludo, obtida através da aquisição da impedância eléctrica. Usando os sinais adquiridos, o utilizador pode também visualizar características do sinal calculadas para segmentos temporais consecutivos com ou sem sobreposição. Finalmente, utilizando as características calculadas ao longo do tempo, o utilizador pode seleccionar um classificador para detetar estados de sonolência. Aquando da detecção de um estado de sonolência, é emitido um sinal de alerta permitindo assim ao utilizador tomar as devidas precauções.

3.3.3. Requisitos Funcionais

Os requisitos funcionais, definem as ações fundamentais da nossa aplicação. Estes requisitos encontram-se apresentados nas Tabela 5 e 6 onde são também apresentadas as prioridades associadas a cada um.

Tabela 5: Requisitos funcionais e suas prioridades.

	Resumo	Prioridade
Requisitos gerais da aplicação	Aquisição dos sinais dos eléctrodos	Must
	Visualização dos sinais dos eléctrodos	Must
	Visualização dos sinais de qualidade dos eléctrodos do <i>hardware Emotiv</i>	Must
	Alarme Sonoro	Must
	Alarme vibratório	Must
	Apresentação do valor da bateria	Should
	Visualização do cálculo das características	Should
	Terminar corretamente a aplicação	Must
	Gravar dados em ficheiros para análise posterior	Must

Estes requisitos são referentes a todas as capacidades da aplicação de apresentar a informação.

Tabela 6: Requisitos de pesquisa e suas prioridades.

	Resumo	Prioridade
Requisitos de pesquisa	Selecionar um eléctrodo desejado	Must
	Selecionar o valor espectral na frequência	Could
	Apresentar apenas valores do sinal de um eléctrodo	Could

3.3.4. Requisitos não funcionais

Estes requisitos devem conter informações como segurança, e encontram-se descritos nas Tabela 7.

Tabela 7: Requisitos não funcionais e suas prioridades.

Resumo	Prioridade
Não partilhar dados sensíveis, com qualquer utilizador.	Must
Aplicação deve funcionar em dispositivos andróide versão 3.1 ou superior e com capacidades de leitura de dispositivo <i>human interface device</i> .	Must
Em caso de falha garantir recuperação do sistema.	Could
Tratamento de ficheiros	Must

3.3.5. Requisitos de interface externa

Estes requisitos são referentes às entradas e saídas de informação e encontram-se descritos na Tabela 8.

Tabela 8: Requisitos de interface externa e suas prioridades.

Resumo	Prioridade
Conexão USB	Must
Conexão com <i>hardware Emotiv</i>	Must

3.4 Desenho da solução

Neste capítulo é apresentada uma breve descrição do projeto assim como as ferramentas usadas para o seu desenvolvimento. São dados detalhes sobre: as técnicas usadas para a implementação do código; a utilização de bibliotecas externas; e os testes efetuados à aplicação, ambicionando uma aplicação com credibilidade e valor.

3.4.1. Desenho do projeto

O nosso projeto tem acesso a dados vindos de um sistema de aquisição de EEG, denominado de sistema *Emotiv*. Este sistema comunica através de uma ligação sem fios com um dispositivo *smartphone*. Seguindo uma arquitetura de alto nível chegou-se ao diagrama apresentado na Figura 21.

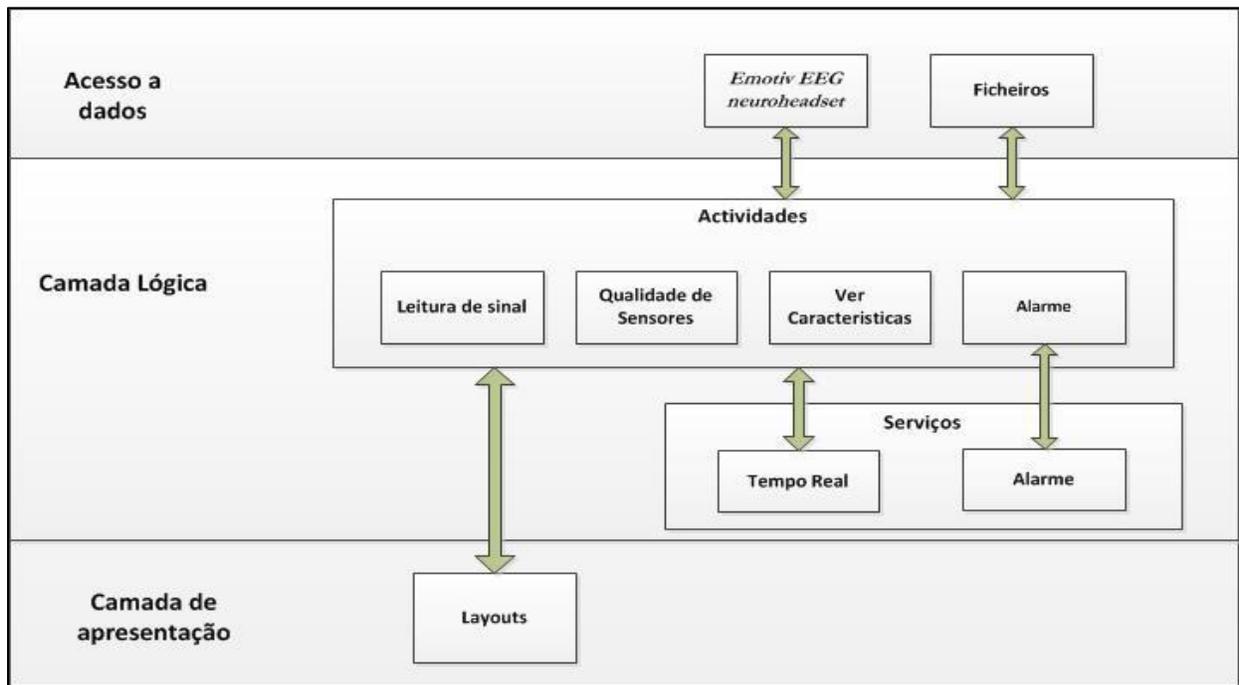


Figura 21: Desenho da arquitectura de alto nível.

Como podemos verificar na Figura 21, a camada lógica é o nosso core da aplicação, é aqui que é tratada a informação. Na camada de aplicação é realizado todo o layout da apresentação, é aqui que o utilizador tem uma visualização dessa informação. No acesso aos dados temos duas ações:

- O *Emotiv* efetua a recolha dos dados dos sinais do EEG.
- Os ficheiros armazenaram os sinais de EEG e respetiva classificação e serviram para a validação dos dados.

A informação dos ficheiros serviu para que os dados recolhidos do funcionamento do sistema fossem analisados por especialista na área e para que os mesmos pudessem ser validados

3.4.2. Tecnologias

Para o desenvolvimento da aplicação fez-se um breve estudo das ferramentas que seriam utilizadas para todo o desenvolvimento, sendo que existiam algumas restrições já desde início entre as quais o tipo *hardware* disponível e a conexão com dispositivo móvel Android. Foram utilizadas também outras ferramentas e plataformas de maneira a poder melhorar o nosso produto final. As ferramentas/plataformas utilizadas foram as seguintes:

- Eclipse Java;
- Matlab;
- Sistema Operativo Windows.

Todas estas ferramentas tiveram como objetivo o desenvolvimento e validação de uma aplicação que foi desenvolvida em ambiente Windows.

O eclipse Java foi a plataforma utilizada para toda a programação Android, pois o mesmo possui módulos que permitem o desenvolvimento de aplicações para dispositivos móveis Android e a programação dos mesmos baseia-se em Java. No final, foi possível através desta plataforma gerar o executável de forma a poder ser instalado em dispositivos móveis.

O Matlab foi a ferramenta onde se realizou toda a análise de dados, uma vez que o mesmo tem capacidade para a implementação de todas as necessidades para extração e classificação de sinal. Foi aqui que foram elaborados todos os estudos acerca do sono e sua classificação que posteriormente foram implementados na aplicação Android de forma a obter-se os melhores resultados possíveis em termos de deteção precoce de estados de pré-sono. Este *software* também permitiu apresentar graficamente os dados obtidos em cada análise.

3.4.3. Ferramentas e Bibliotecas de Apoio

Para este projeto foi necessário utilizar bibliotecas para obter valores da transformada rápida de Fourier, essencial para o cálculo das características espectrais, assim como uma biblioteca gráfica para apresentação de resultados.

Para o cálculo da transformada rápida de Fourier foi utilizada a biblioteca JMathStudio.jar pelo facto de a mesma ter capacidade de cálculo compatível com as nossas necessidades.

Para a criação de gráficos em tempo real foi utilizada a biblioteca GraphView-3.1.1.jar, a utilização da mesma deveu-se à capacidade que a mesma dispõem para uma apresentação em tempo real e pelo tipo de formatação que disponibiliza. Ainda foram experimentados outras bibliotecas neste campo, tais como AFreechart, AndroidPlot, e ChartView, mas não cumpriram as nossas necessidades.

Para análise de classificadores no Android foi utilizada a biblioteca LibSVM, biblioteca essa que nos permitiu obter o valor de saída do classificador. Para se obter a saída relativamente aos dados que foram analisados, esta biblioteca apenas necessita do modelo de treino do classificador, modelo esse treinado em Matlab.

Em Matlab foi utilizada uma *toolbox* de seu nome *stprtool* [78] para que o desenvolvimento dos classificadores fosse mais simples e rápida. Através desta *toolbox* foi possível apresentar os cálculos e os resultados obtidos pelos diversos classificadores analisados. Todos os resultados apresentados aqui neste relatório também advém do Matlab, pois esta ferramenta é muito completa o que permite fazer uma análise muito discriminativa de resultados obtidos de varias áreas.

3.4.4. Testes da aplicação

Para verificar se a nossa aplicação estava a funcionar corretamente foi necessário proceder a testes de qualidade e de capacidade de resposta aquando da existência de uma falha. Os testes são uma parte fundamental de qualquer projeto pois só assim é possível verificar se a aplicação se encontra a funcionar corretamente e proceder-se à validação de vários aspetos da aplicação. Para isso foi elaborado um conjunto de testes por forma a perceber qual o comportamento da aplicação e quais os passos a seguir no caso de falha.

Todos os testes elaborados foram uma mais valia para um correto funcionamento da aplicação assim como de toda a análise dos cálculos em causa, sendo que os testes efetuados e os seus resultados encontram-se descritos no Anexo B.

3.5 Seleção de elétrodos e extração de características

3.5.1. Seleção de elétrodos

Uma vez que os elétrodos EEG recolhem informação de diversas partes do cérebro, foi necessário recorrer a especialistas na área para saber quais os melhores elétrodos para a deteção de sonolência. Os mesmos indicaram que os melhores elétrodos para o efeito são os que se encontram na parte central do cérebro. Como o *hardware Emotiv* não permite a aquisição das posições centrais (como por

exemplo Fz, Cz, Pz), como se pode observar na secção 3.1, escolhemos quatro elétrodos relativamente perto da parte central do couro cabeludo. Assim, usámos:

- F3
- F4
- O1
- O2

Os elétrodos AF3 e AF4, embora estejam próximos da área central, foram descartados, uma vez que os sinais disponibilizados pelos parceiros clínicos para desenvolvimento do sistema não incluíam estes elétrodos.

3.5.2. Transformada rápida de Fourier

O algoritmo FFT foi proposto por J.W. Cooley (IBM) em colaboração com J.W. Tukey (Bell Labs) para o tratamento digital de sinais, em 1965 [19], e é usado neste trabalho. Este algoritmo é uma melhoria em termos de velocidade de cálculo do algoritmo que implementa a transformada discreta de Fourier (DFT) e a sua inversa. A DTF (X_k) de uma sequência discreta $x(n)$ de N amostras é definida pela seguinte equação [75]:

$$X_k = \sum_{n=0}^{N-1} x(n)W_N^{kn} \quad 0 \leq k \leq N - 1 \quad (35)$$

Onde,

$$W_N = e^{-i2\pi/N} \quad (36)$$

Se $N=2^n$ e com o N inteiro positivo, podemos dizer que $N=2M$ para um M inteiro positivo e fazendo a substituição podemos concluir [75]:

$$\begin{aligned} X_k &= \frac{1}{2M} \sum_{n=0}^{2M-1} x(n)W_{2M}^{kn} \\ &= \frac{1}{2} \left\{ \frac{1}{M} \sum_{n=0}^{M-1} x(n)W_{2M}^{k(2n)} + \frac{1}{M} \sum_{n=0}^{M-1} x(2n+1)W_{2M}^{k(2n+1)} \right\} \end{aligned} \quad (37)$$

Assim , voltando à equação 36 podemos dizer que $W_{2M}^{2kn} = W_{2M}^{kn}$ e com a anterior 37, temos:

$$X_k = \frac{1}{2} \left\{ \frac{1}{M} \sum_{n=0}^{M-1} x(2n) W_M^{kn} + \frac{1}{M} \sum_{n=0}^{M-1} x(2n+1) W_M^{kn} W_{2M}^k \right\} \quad (38)$$

Define-se assim:

$$F_{par}(k) = \frac{1}{M} \sum_{n=0}^{M-1} x(2n) W_M^{kn} \quad \text{para } k=0,1,\dots, M-1 \quad (39)$$

$$F_{impar}(k) = \frac{1}{M} \sum_{n=0}^{M-1} x(2n+1) W_M^{kn} \quad \text{para } k=0,1,\dots, M-1 \quad (40)$$

Voltando então às expressões 39 e 40 temos que:

$$F(k) = \frac{1}{2} \{ F_{par}(k) + F_{impar}(k) W_{2M}^k \} \quad (41)$$

Também dado que $W_M^{k+M} = W_M^k$ e $W_{2M}^{k+M} = -W_{2M}^k$,

$$F(k+M) = \frac{1}{2} \{ F_{par}(k) + F_{impar}(k) W_{2M}^k \} \quad (42)$$

Em termos de processamento, a função para cada N tem uma saída X_k , daí a complexidade de DFT[75] ser de $O(N^2)$, sendo que a FFT faz o mesmo cálculo com uma complexidade de $O(N \log N)$.

3.5.3. Análise contínua de sinais

A análise contínua dos sinais de EEG, representada na Figura 22, envolveu a delimitação do sinal em porções (janelamento) que permitiram a execução dos algoritmos de extração de características e de classificação. Neste estágio foi considerada como adequada uma janela de 5 segundos com uma sobreposição entre janelas consecutivas de 2 segundos. Para cada porção de sinal foram extraídas as

diferentes características (apresentadas na Secção 2.3), formando um vetor que posteriormente foi classificado.

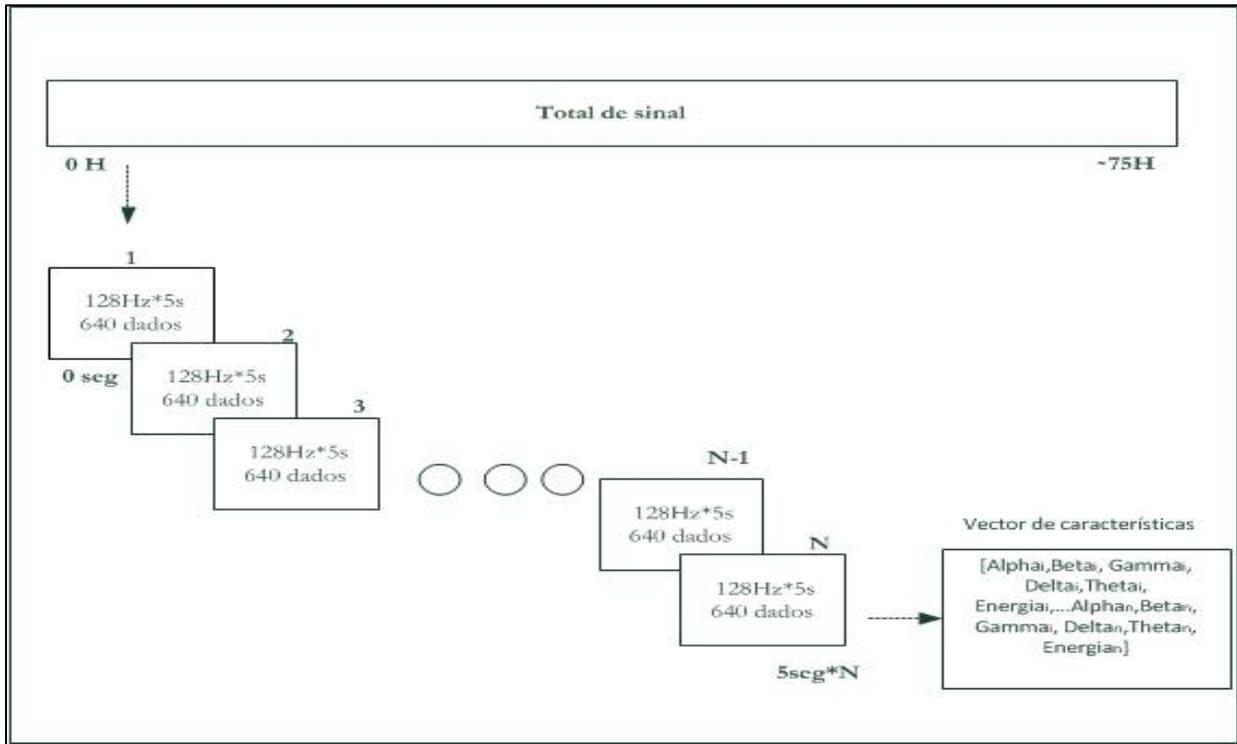


Figura 22: Análise contínua de sinais.

A forma genérica do vetor de características para a n -ésima janela e para o k -ésimo electro será:

$$V_k[n] = \begin{bmatrix} \bar{X}_k[n] \\ \sigma_k^2[n] \\ \chi_k[n] \\ \kappa_k[n] \\ E_k[n] \\ \delta_k[n] \\ \vartheta_k[n] \\ \alpha_k[n] \\ \beta_k[n] \\ \gamma_k[n] \\ HM_k[n] \\ HC_k[n] \end{bmatrix}$$

Assim, conseguimos ter as características relativas a cada eléctrodo ao longo do tempo. Posteriormente e como se encontra descrito no Capítulo 6, foi feita uma análise da capacidade de cada característica para detetar estados de sonolência. Após esta análise discriminativa somente as melhores características serviram como entrada para os classificadores.

3.6 Métodos de análise

Após a extração de características foi efetuado um estudo sobre a sua capacidade para detecção de estados de sonolência e posteriormente as características mais discriminativas foram usadas como entradas para os classificadores.

A análise da capacidade discriminativa, bem como da performance dos classificadores e a significância estatística dos resultados foram feitos recorrendo a um conjunto de técnicas descritas nesta secção.

3.6.1. Curva de ROC, matriz de confusão e métricas de performance

A *Receiver Operating Characteristic* (ROC) é uma técnica para a visualização, organização e seleção de classificadores com base em seu desempenho, tendo evoluído na visualização e análise do comportamento de sistemas de diagnóstico [67].

As curvas ROC têm sido muito utilizados na teoria de detecção de sinais para descrever o equilíbrio entre as taxas de verdadeiros alarmes e taxas de falsos alarmes de classificadores, muito em particular na área do diagnóstico médico [67].

A construção de uma curva ROC é obtida através da escolha de vários limiares de decisão e observando para cada limiar o desempenho de classificação, como é exemplificado na Figura 23.

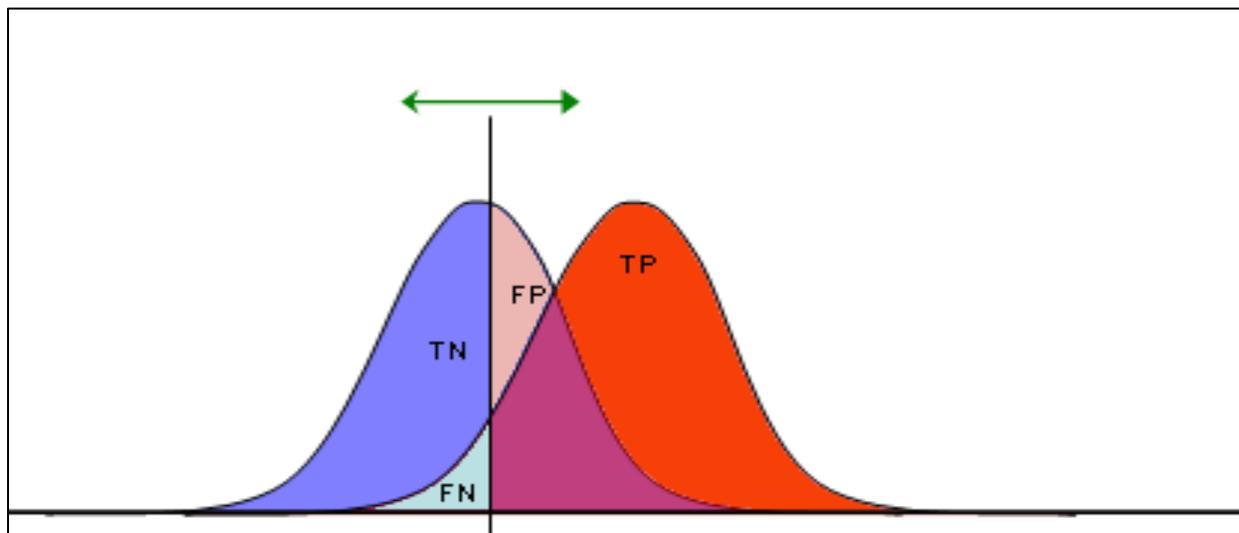


Figura 23: Exemplificação da obtenção da curva ROC [68]. A linha vertical indica um limiar arbitrário e variável. A área a vermelho representa os verdadeiros positivos, a área a azul os verdadeiros negativos, a região a azul esverdeado (ciano) os falsos negativos e a região a rosa os falsos positivos [79].

De uma forma mais detalhada, a curva ROC é um gráfico de sensibilidade (ou taxa de verdadeiros positivos) em função taxa de falsos positivos (ou 1-specificidade). A avaliação do desempenho do classificador é feita pela curva que mostra a taxa de verdadeiros positivos (sensibilidade) no eixo “y”

e a taxa de falsos positivos (1-especificidade) no eixo “x” [68]. Um parâmetro comum utilizado para avaliar o desempenho de um classificador é a área sob a curva ROC, (Area Under the ROC curve - AUC). A área sob a curva é um valor entre 0 e 1. Quanto maior a área sob a curva melhor o desempenho do classificador, sendo os mesmos classificados por [69]:

- .90 - 1 → Muito bom
- .80 - .90 → Bom
- .70 - .80 → Suficiente
- .50 - .70 → Medíocre
- .50 → Aleatório

De forma análoga podemos construir para cada limiar de decisão uma matriz de confusão, como se mostra na Figura 24.

		Condição (Determina se está em estado de sonolência)	
		Positivo	Negativo
Resultado do Teste	Positivo	Verdadeiros Positivos (VP)	Falsos Positivos (FP)
	Negativo	Falsos Positivo (FP)	Verdadeiros Negativos (VN)

Figura 24: Matriz de confusão genérica [69].

Através da matriz de confusão podemos obter diversas medidas de performance de classificação, descritas pelas equações seguintes [69]:

Sensibilidade:

É conhecida também por *recall* ou *true positive rate (TPR)*:

$$\mathbf{TPR} = \text{VP} / (\text{VP} + \text{FN}) \quad (43)$$

Especificidade:

Pode ser também chamada de *True Negative Rate (SPC)*:

$$\mathbf{SPC} = \text{VN} / (\text{FP} + \text{VN}) \quad (44)$$

Precisão:

Conhecida também por *positive predictive value (PPV)*, sendo o seu valor obtido pela função:

$$\mathbf{PPV} = \text{VP}/(\text{VP}+\text{FP}) \quad (45)$$

Fall-out:

Ou False positive Rate (FPR), obtida pela função a seguir apresentada:

$$\mathbf{FPR} = \text{FP}/(\text{FP}+\text{VN}) \quad (46)$$

3.6.2. Kruskal-Wallis

Pode dizer-se que o teste *Kruskal-wallis* é uma alternativa não paramétrica ao teste ANOVA, no qual não se assume que os dados tenham uma distribuição normal [73]. No entanto, assume que as observações em cada grupo vêm de populações com a mesma forma de distribuição [73]. Neste projeto foi utilizado o *Kruskal-wallis* para verificar a significância estatística dos estudos realizados, para isso é necessário obter o valor de *P value*. Para obtenção do valor *P value* tem que se efetuar a seguinte análise [74]:

$$K = (N - 1) \frac{\sum_{i=1}^g n_i (\bar{r}_i - \bar{r})^2}{\sum_{i=1}^g \sum_{j=1}^{n_i} (r_{ij} - \bar{r})^2} \quad (47)$$

- n_i é o número de observações no grupo i
- r_{ij} é a classificação de todas as observações de j no grupo i
- N é o total de todas as observações
- $\bar{r}_i = \frac{\sum_{j=1}^{n_i} r_{ij}}{n_i}$
- $\bar{r} = (N + 1)/2$ é a média de r_{ij} .

O valor de *P value* advém da aproximação de $\Pr(\chi_{g-1}^2 \geq K)$, se algum n_i é inferior a 5 a distribuição de probabilidade K não pode ser definida pela distribuição chi-quadrado (χ^2).

Existem alguns autores [72] que fazem uma distinção do valor do *P value* (grau de significância) e utilizam também alguns símbolos como anotações para descrever a significância dos dados. Estas anotações não são standardizadas [72].

Tabela 9: Valores do *P value* [72].

<i>P value</i>	Discrição	Notação
>0.05	Não significativa	ns
0.01 to 0.05	Significante	*
0.001 to 0.01	Muito significativa	**
<0.001	Extremamente significativa	***

É através da classificação do *P value* que averiguamos se determinados estudos têm ou não significância estatística, por exemplo se o efeito da idade dos indivíduos resulta em diferenças estatisticamente significantes.

3.7 Teste e validação

O passo final deste projeto foi a análise em tempo real da estratégia de classificação desenvolvida. Inicialmente procedeu-se à recolha de dados em várias pessoas durante algum tempo para conseguir-se obter dados que nos permitissem verificar a ocorrência de estados de sonolência e obter os resultados da classificação do sistema. Finalmente os resultados de classificação do sistema foram confrontados com a classificação efetuada por clínicos do Centro Hospitalar e Universitário de Coimbra.

Desta forma, para se proceder à validação dos testes efetuados, foram guardados os sinais de EEG do utilizador durante um determinado tempo e assim que o dispositivo detetou a ocorrência de um estado de sonolência, efetuou um registo do momento (hora: minuto: segundo) no qual a mesma ocorreu. No final, os sinais de EEG e os estados de sonolência registados automaticamente pelo sistema foram enviados aos clínicos, que procederam a uma validação detalhada dos resultados obtidos.

Capítulo 4

Resultados & Discussão

Neste capítulo são apresentados os estudos efetuados em torno da deteção do estado de pré-sono. Para o desenvolvimento do sistema de classificação foram levados a cabo dois estudos principais. Um primeiro estudo foi efetuado na base de dados “The Sleep-EDF Database” [71], tendo como objetivo a obtenção de conhecimento inicial sobre o problema em causa numa base de dados validada. O segundo estudo usou dados recolhidos no Centro Hospitalar e Universitário de Coimbra e, conjuntamente com as observações do estudo preliminar, levaram ao desenvolvimento e análise de diversas abordagens de classificação.

A análise da capacidade discriminativa de cada característica foi feita recorrendo a curvas ROC, ou seja, recorrendo ao cálculo da AUC. Com base nos valores da AUC foi possível averiguar quais as características mais importantes, bem como avaliar a influência dos diversos parâmetros dos dados (elétrodos) e dos indivíduos (sexo e idade).

Finalmente, através da escolha das duas características mais importantes para o problema em causa foram desenvolvidos diversos tipos de classificador.

4.1 Estudo Preliminar

4.1.1 Descrição dos dados

A base de dados usada para o estudo preliminar é formada por dados de 15 indivíduos, onde para cada indivíduo encontra-se disponível o EEG para as combinações de elétrodos Pz-Oz e Fpz-Cz, adquiridos a uma frequência de amostragem de 128Hz. Dos 15 indivíduos, 6 são homens, 9 são mulheres. As idades dos indivíduos encontram-se distribuídas entre 23 e 33 anos, sendo que 8 têm menos de 30 anos, e 7 mais que 30 anos.

4.1.2 Análise Discriminatória

Na Tabela 10 e Figura 25 podemos observar os resultados relativamente à combinação Pz-Oz:

Tabela 10: Resultados das características de Pz-Oz.

Característica	AUC
Beta	0,9606
Gamma	0,9444
Mobilidade Hjorth	0,9367
Complexidade Hjorth	0,9285
Alpha	0,7204
Curtose	0,6801
Energia	0,5319
Variância	0,5311
Media	0,5099
Assimetria	0,4843
Theta	0,3639
Delta	0,1316

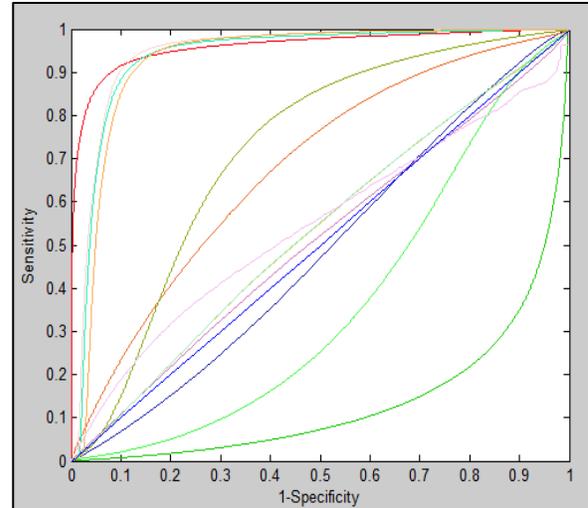


Figura 25: Curva Roc dos resultados relativos à combinação Pz-Oz.

Como pode verificar-se, os dados relativos às potências relativas nas bandas Beta e Gamma estão muito bem caracterizados e dão-nos uma sensibilidade/especificidade muito elevada, a qual nos leva mesmo a dizer que, apenas com um classificador linear podemos facilmente detetar os estados "acordado" e a "dormir".

Já para uma análise dos elétrodos referentes a Fpz-Cz, seguindo as mesmas características anteriores obtivemos os seguintes resultados:

Tabela 11: Resultados das características de Fpz-Cz.

Característica	AUC
Gamma	0,7490
Energia	0,7336
Variância	0,7329
Complexidade Hjorth	0,7269
Curtose	0,6785
Mobilidade Hjorth	0,6782
Beta	0,6617
Delta	0,5262
Media	0,5108
Assimetria	0,4096
Theta	0,3897
Alpha	0,3735

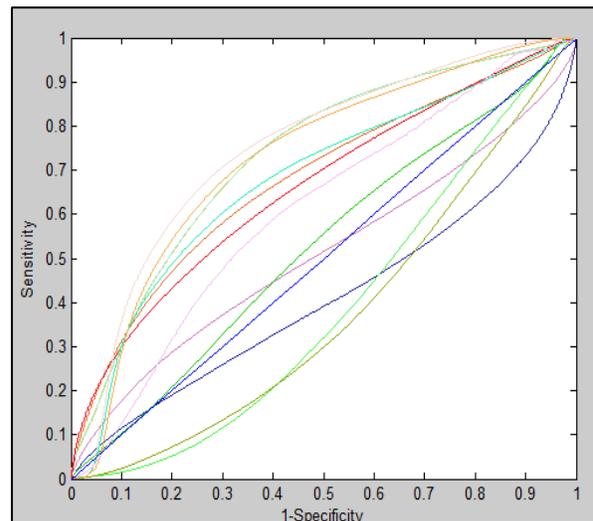


Figura 26: Curva Roc dos resultados.

Como podemos verificar, através da análise das curvas ROC, os dados dos eléctodos Pz-Oz são bastante melhores que os dos Fpz-Cz.

Neste caso os valores de AUC obtidos são muito abaixo do que os apresentados anteriormente. Mesmo em termos de características, existem mudanças notórias. Não sendo assim possível verificar corretamente os dados relativos aos estados "acordado" e "dormir" para os dados dos eléctodos em causa.

São apresentadas nas figuras seguintes características relacionadas com as potências relativas, onde a linha a vermelho representa a classificação de acordado/dormir ao longo do tempo. Mais precisamente, se uma pessoa se encontra a dormir a linha vermelha assume o valor "0", caso contrário assume o valor "1".

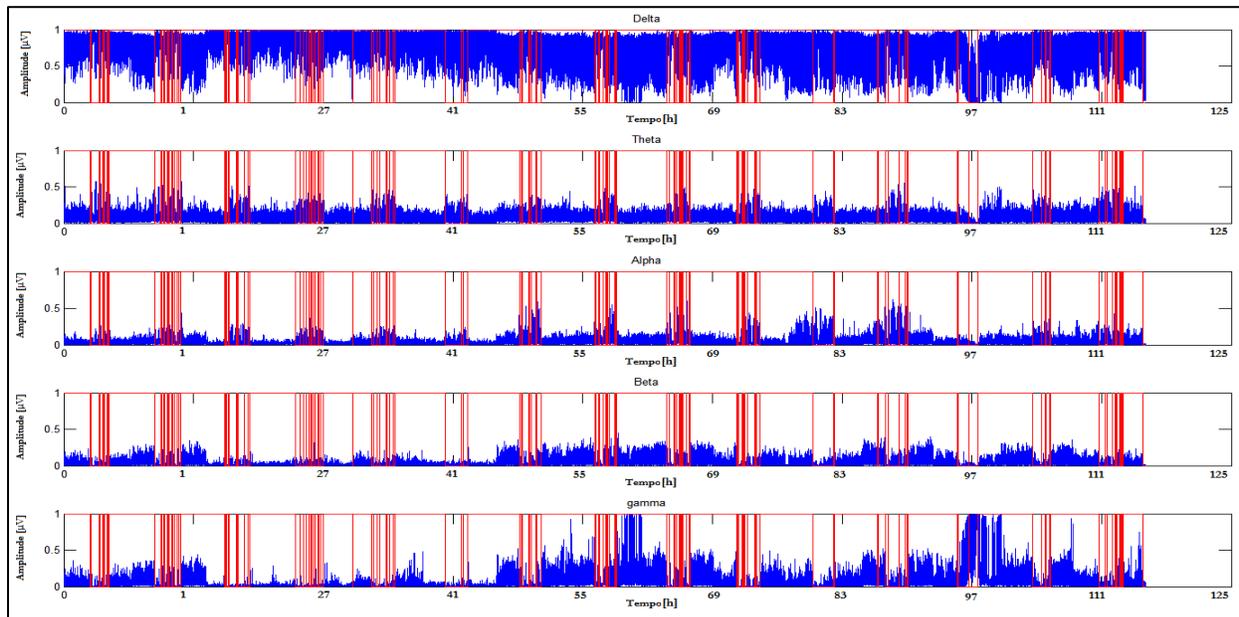


Figura 27: Características Fpz-Cz.

Como podemos ver, o melhor resultado é obtido no sinal referente à potência relativa na banda Gamma. Os valores das características dos eléctodos Fpz-Cz não são tão discriminativos como os que são apresentados a seguir para Pz-Oz, podendo neste caso haver mais falhas na detecção do estado de pré-sono. Da simples análise visual do gráfico da Figura 27 podemos facilmente identificar os estados de "dormir" e "acordado".

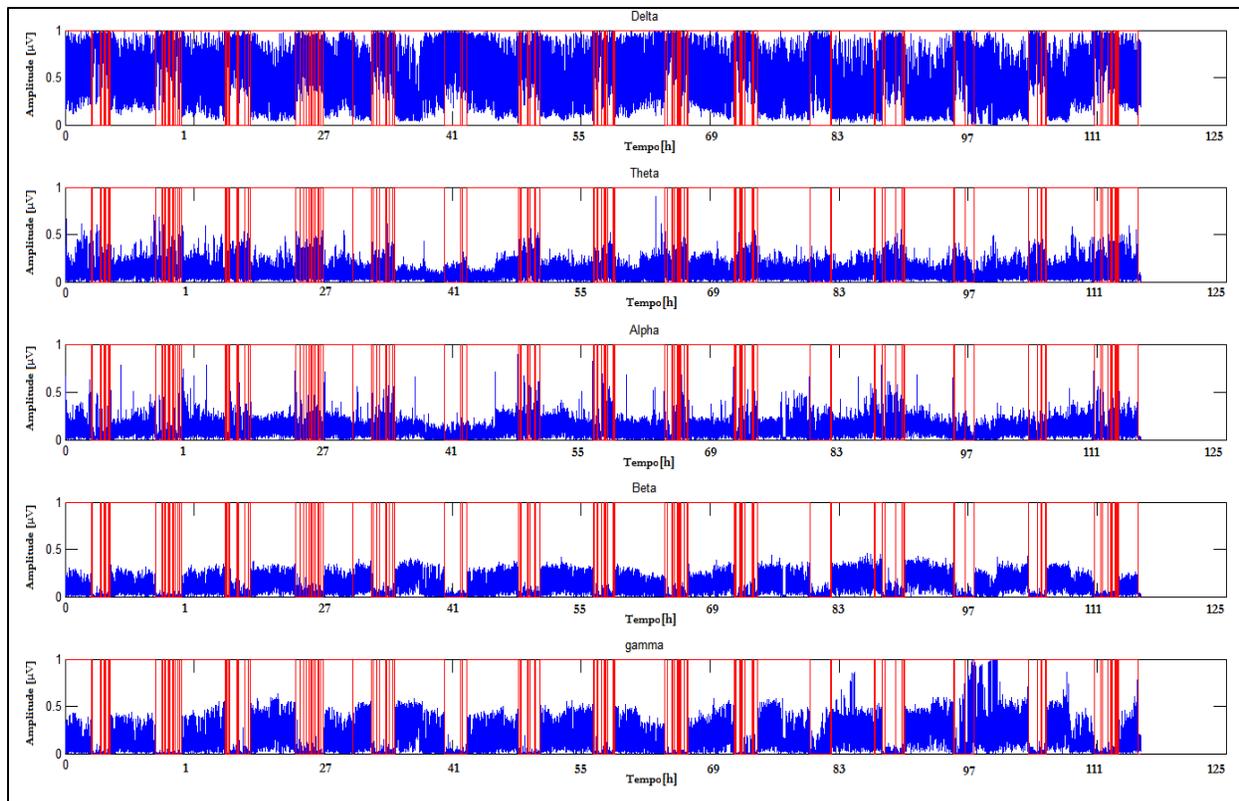


Figura 28: Características Pz-Oz.

Através das duas figuras anteriores podemos ver que as potências relativas caracterizam muito bem os estados em que os pacientes se encontram, podendo efetuar-se uma boa análise e retirar as melhores ilações acerca dos mesmos. Podemos desde já dizer que os dados dos elétrodos Pz-Oz são muito discriminativos (nas potências relativas nas bandas Beta e Gamma) os quais permitem detetar até visualmente quando a linha vermelha se encontra =1 (acordado) ou =0 (dormir).

Deste modo, este estudo preliminar indica que as regiões posteriores do cérebro são as melhores para a classificação de sono.

Analisando separadamente as AUC obtidas para indivíduos dos sexos masculino e feminino foram obtidos os seguintes resultados:

Tabela 12: Características Mulheres Pz-Oz.

Característica	AUC
Beta	0,9617
Gamma	0,9609
Mobilidade Hjorth	0,9499
Complexidade Hjorth	0,9440
Alpha	0,7164
Curtose	0,6841
Energia	0,5132
Variância	0,5122
Média	0,5071
Assimetria	0,4690
Theta	0,3564
Delta	0,1356

Tabela 13: Características Homens Pz-Oz.

Característica	AUC
Beta	0,9582
Gamma	0,9189
Mobilidade Hjorth	0,9163
Complexidade Hjorth	0,9053
Alpha	0,7290
Curtose	0,6748
Energia	0,5570
Variância	0,5568
Média	0,5172
Assimetria	0,5079
Theta	0,3743
Delta	0,1353

Tabela 14: Características Mulheres Fpz-Cz.

Característica	AUC
Gamma	0,7697
Complexidade Hjorth	0,7491
Energia	0,7183
Variância	0,7175
Curtose	0,6942
Mobilidade Hjorth	0,6732
Beta	0,6037
Delta	0,5454
Média	0,5183
Assimetria	0,3981
Theta	0,3542
Alpha	0,3313

Tabela 15: Características Homens Fpz-Cz.

Característica	AUC
Energia	0,7551
Variância	0,7545
Beta	0,7447
Gamma	0,7192
Complexidade Hjorth	0,6889
Mobilidade Hjorth	0,6701
Curtose	0,6594
Delta	0,5128
Média	0,4981
Theta	0,4365
Assimetria	0,4264
Alpha	0,4244

Como pode verificar-se pela figura abaixo, existe alguma diferença quando analisamos separadamente indivíduos de sexo diferente. Pode dizer-se que para o sexo feminino as melhores características extraídas da combinação Pz-Oz são ligeiramente mais discriminativas.

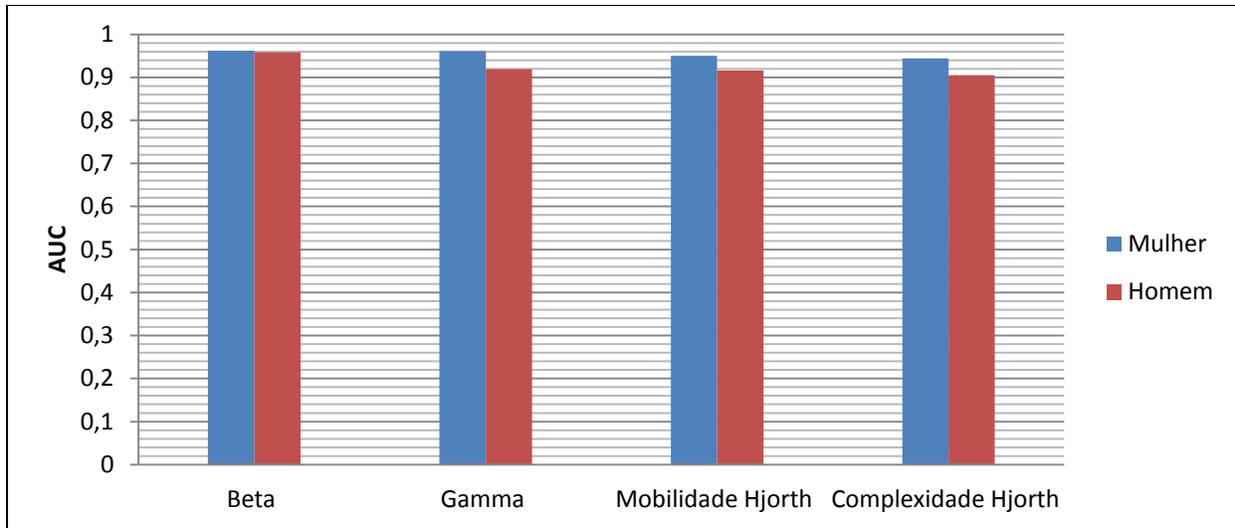


Figura 29: As quatro melhores características do elétrico Pz-Oz em função do sexo dos indivíduos.

Ainda relativamente às melhores características, as mesmas para ambas as combinações de eletrodos conseguem obter um grande desempenho, como é descrito na figura seguinte.

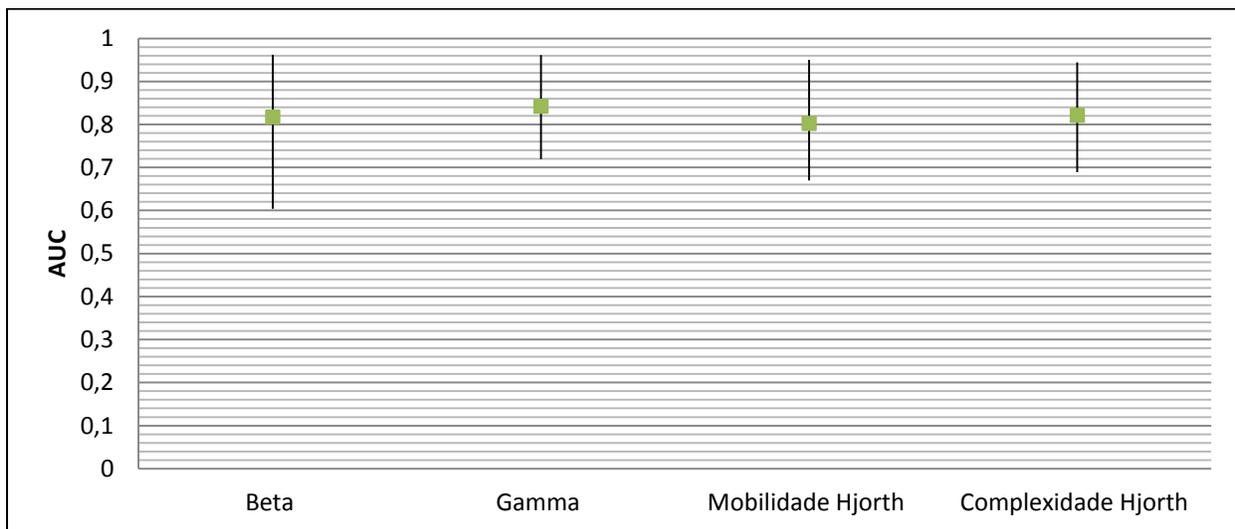


Figura 30: Valor máximo, mínimo e médio das melhores características.

Para concluir, foram analisadas as idades para verificar a existência de alguma melhoria. As mesmas foram divididas em duas partes:

- Idade menor que 30 anos.
- Idade maior que 30 anos.

Para estas duas variáveis de idades obtivemos os seguintes resultados aqui apresentados:

Tabela 16: Idade maior.

Característica	AUC
Beta	0,9613
Gamma	0,9517
Mobilidade Hjorth	0,9441
Complexidade Hjorth	0,9303
Alpha	0,7316
Curtose	0,6872
Média	0,5046
Energia	0,4931
Variância	0,4926
Assimetria	0,4616
Theta	0,3416
Delta	0,1326

Tabela 17: Idade menor.

Característica	AUC
Beta	0,9604
Gamma	0,9375
Mobilidade Hjorth	0,9290
Complexidade Hjorth	0,9265
Alpha	0,7152
Curtose	0,6744
Energia	0,5631
Variância	0,5624
Média	0,5160
Assimetria	0,5042
Theta	0,3836
Delta	0,1376

Como pode verificar-se, existe variação entre as idades, sendo que ambas obtêm praticamente o mesmo resultado para cada característica em estudo, o que nos leva a concluir que as idades não têm influência no nosso estudo. Não foi elaborado um estudo acerca dos sensores FPz-Cz uma vez que verificámos que não tinham nenhum dado que iria ser importante para a análise em estudo.

Com esta análise podemos verificar agora os dados que nos foram fornecidos pelo Hospital da universidade de Coimbra e verificar os dados para os elétrodos que o *Emotiv* dispõem, melhorando a nossa análise de elétrodos e dados.

4.2 Estudo com dados recolhidos no Centro Hospitalar e Universitário de Coimbra

4.2.1 Descrição dos dados

Os dados analisados foram coletados de 8 indivíduos, de ambos os sexos, com uma aparente vida saudável e normal, sendo que as idades variavam entre os 15 e os 46 anos. Para cada indivíduo encontra-se disponível o EEG adquirido a 256Hz e segundo o sistema internacional 10-20, onde se incluem os elétrodos colocados nas posições F3, F4, O1 e O2. Nos dados existem três mulheres e cinco homens. Os dados referentes aos diferentes indivíduos foram todos juntos de forma a ter apenas um conjunto de dados. Os mesmos dados foram ainda agrupados por sexo e idade de forma a poder retirar-se algumas conclusões e ajustes.

De referir que os diferentes estádios do sono foram catalogados manualmente por clínicos experientes o que permitiu a construção de uma saída desejada (target) para a análise e treino dos classificadores.

4.2.2 Análise Discriminatória

Para os elétrodos selecionados, isto é, F3,F4, O1 e O2, foram analisadas as características já anteriormente selecionadas para o estudo preliminar. Foi também analisada a influência do sexo na capacidade discriminatória das características extraídas para os diferentes elétrodos. No final foi feita uma análise geral, visando a extração de conclusões relativamente às diferenças impostas pelos diferentes aspetos dos dados e dos indivíduos.

- **Eléttrodo F3**

Nas tabelas seguintes são apresentados os resultados obtidos mais uma vez apresentados em termos de AUC.

Tabela 18: Dados mulher eléttrodo F3.

Característica	AUC
Beta	0,6336
Assimetria	0,6185
Gamma	0,5886
Theta	0,5829
Complexidade Hjorth	0,5753
Mobilidade Hjorth	0,5747
Variância	0,5516
Energia	0,5368
Delta	0,5309
Curtose	0,5264
Alpha	0,5079
Média	0,4905

Tabela 19: Dados homem eléttrodo F3.

Característica	AUC
Assimetria	0,6516
Beta	0,6161
Curtose	0,6029
Gamma	0,5608
Complexidade Hjorth	0,5588
Mobilidade Hjorth	0,5390
Theta	0,5289
Média	0,5018
Alpha	0,5016
Energia	0,4736
Variância	0,4710
Delta	0,4710

Tabela 20: Dados elétrodo F3.

Característica	AUC
Assimetria	0,6689
Beta	0,6105
Curtose	0,6021
Theta	0,5458
Gamma	0,5185
Alpha	0,5167
Complexidade Hjorth	0,5128
Média	0,5005
Mobilidade Hjorth	0,4985
Delta	0,4956
Variância	0,4714
Energia	0,4706

Como pode verificar-se não existe uma grande diferença imposta pelo sexo dos indivíduos. Como nota principal há que referir que obtivemos um valor muito baixo para a nossa melhor característica, a Assimetria (*skewness*). Na Figura 31 podemos visualizar as diferenças impostas pelo sexo na capacidade discriminatória das diferentes características.

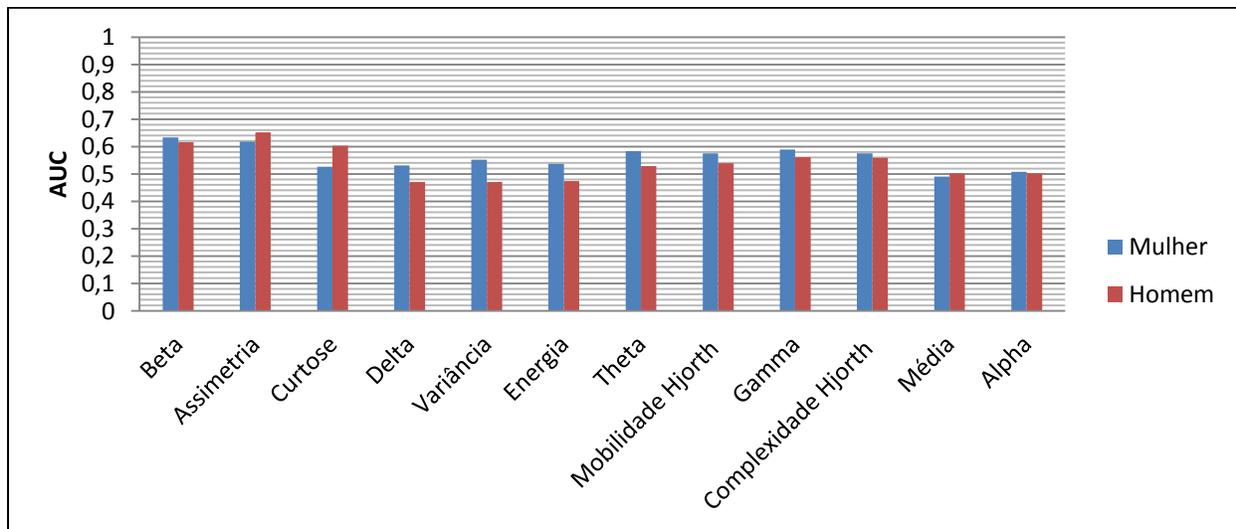


Figura 31: Características do elétrodo F3.

Na Figura 32 encontra-se representada graficamente a evolução de algumas das características. A linha verde representa a classificação de acordado/dormir ao longo do tempo. Mais precisamente, se uma pessoa se encontra a dormir, a linha verde assume o valor “0”, caso contrário assume o valor “1”.

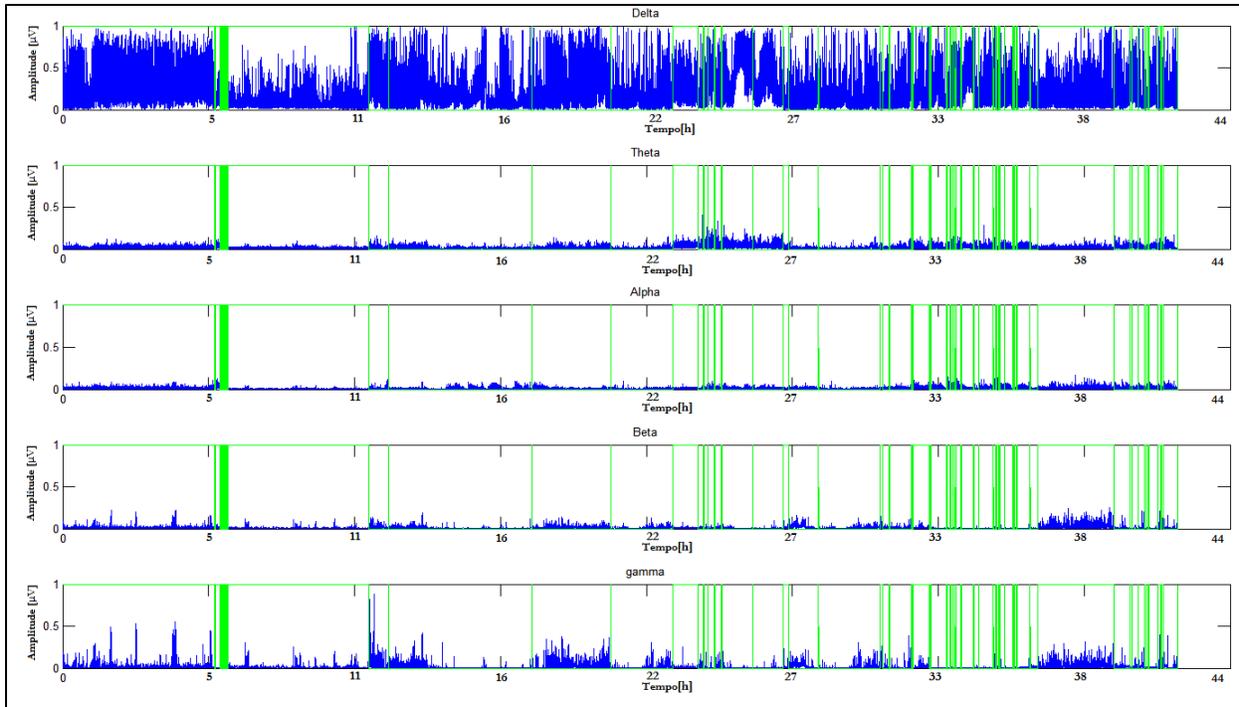


Figura 32: Evolução temporal das potências relativas nas diversas bandas para o eléctrodo F3.

- **Eléctrodo F4**

Para o eléctrodo F4 foi realizado o mesmo estudo para descobrir se o mesmo vem melhorar os resultados obtidos pelo eléctrodo F3.

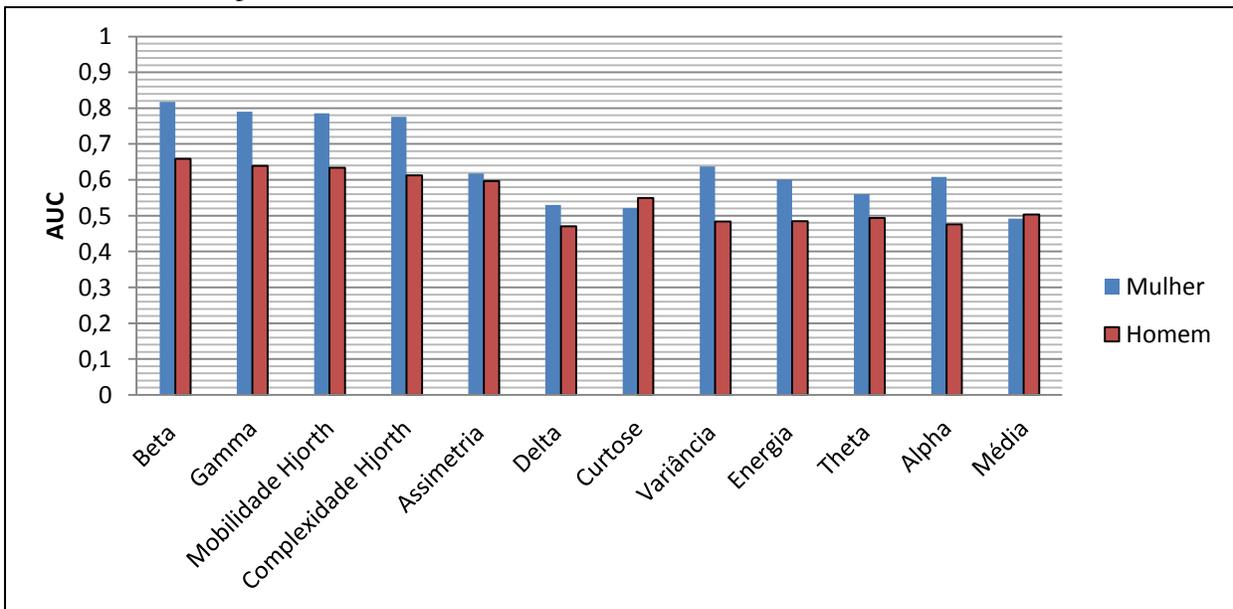


Figura 33: Valores obtidos nas características F4 referentes ao sexo.

Tabela 21: Dados mulher elétrodo F4.

Característica	AUC
Beta	0,8179
Gamma	0,7902
Mobilidade Hjorth	0,7857
Complexidade Hjorth	0,7760
Variância	0,6374
Assimetria	0,6178
Alpha	0,6080
Energia	0,5997
Theta	0,5603
Delta	0,5301
Curtose	0,5215
Média	0,4919

Tabela 22: Dados homem elétrodo F4.

Característica	AUC
Beta	0,6586
Gamma	0,6388
Mobilidade Hjorth	0,6335
Complexidade Hjorth	0,6123
Assimetria	0,5965
Curtose	0,5497
Média	0,5033
Theta	0,4936
Energia	0,4849
Variância	0,4840
Alpha	0,4761
Delta	0,4705

Tabela 23: Dados elétrodo F4.

Característica	AUC
Beta	0,6974
Gamma	0,6460
Mobilidade Hjorth	0,6389
Complexidade Hjorth	0,6294
Assimetria	0,6021
Curtose	0,5492
Alpha	0,5313
Theta	0,5113
Variância	0,5058
Média	0,5018
Energia	0,4977
Delta	0,4944

Continuamos a constatar que as características para indivíduos do sexo feminino são mais discriminativas obtendo assim um valor quase sempre superior, tanto no elétrodo F4 como no F3.

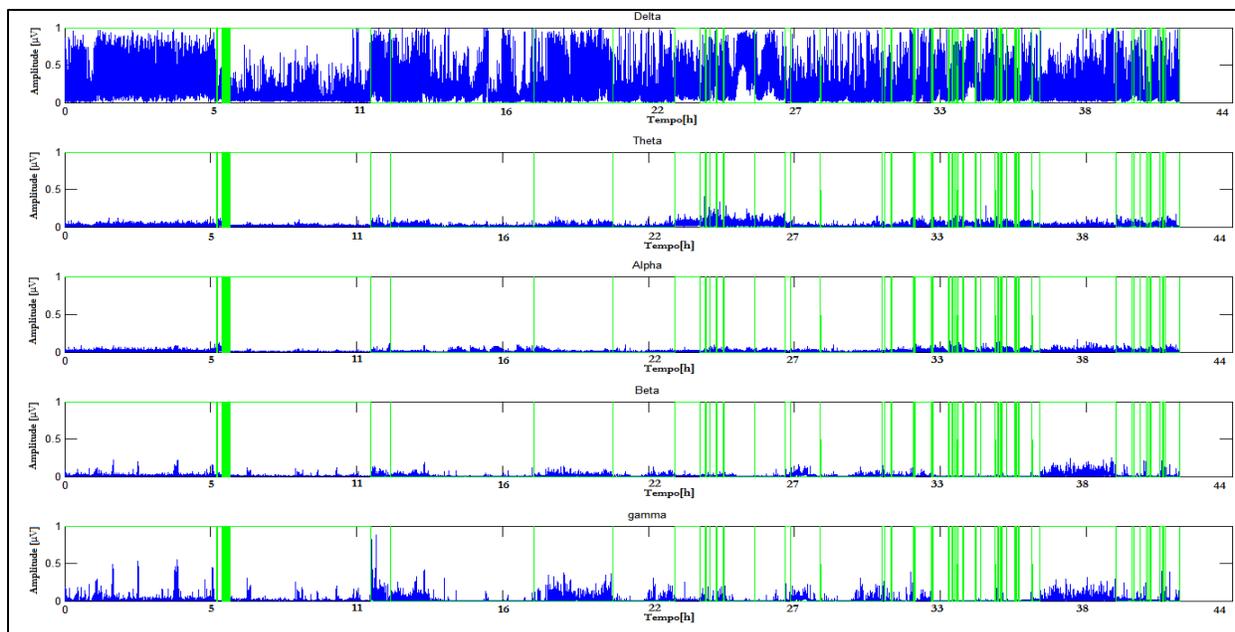


Figura 34: Evolução temporal das potências relativas nas diversas bandas para o elétrodo F4.

Os resultados obtidos continuam a não ser muito discriminativos para os elétrodos F4 e F3, sendo que a característica mais discriminativa continua a ser o beta.

- **Elétrodo O1**

No caso do elétrodo O1 a sua localização é na parte posterior de cérebro, numa zona mais central do mesmo, e podemos verificar que os resultados melhoraram significativamente em ambos os sexos.

Tabela 24: Dados mulher elétrodo O1.

Característica	AUC
Gamma	0,8389
Mobilidade Hjorth	0,8327
Complexidade Hjorth	0,8274
Beta	0,8227
Variância	0,6865
Alpha	0,6680
Energia	0,6351
Delta	0,5745
Theta	0,5537
Média	0,5024
Assimetria	0,4812
Curtose	0,3995

Tabela 25: Dados homem elétrodo O1.

Característica	AUC
Beta	0,8326
Mobilidade Hjorth	0,8051
Gamma	0,7842
Complexidade Hjorth	0,7701
Alpha	0,7692
Variância	0,6312
Theta	0,6079
Energia	0,6063
Delta	0,5652
Média	0,5029
Curtose	0,4929
Assimetria	0,4167

Tabela 26: Dados elétrico O1.

Característica	AUC
Beta	0,8712
Mobilidade Hjorth	0,8339
Gamma	0,8242
Complexidade Hjorth	0,8089
Alpha	0,7658
Variância	0,6242
Energia	0,5946
Theta	0,5925
Delta	0,5690
Média	0,5030
Curtose	0,4773
Assimetria	0,4768

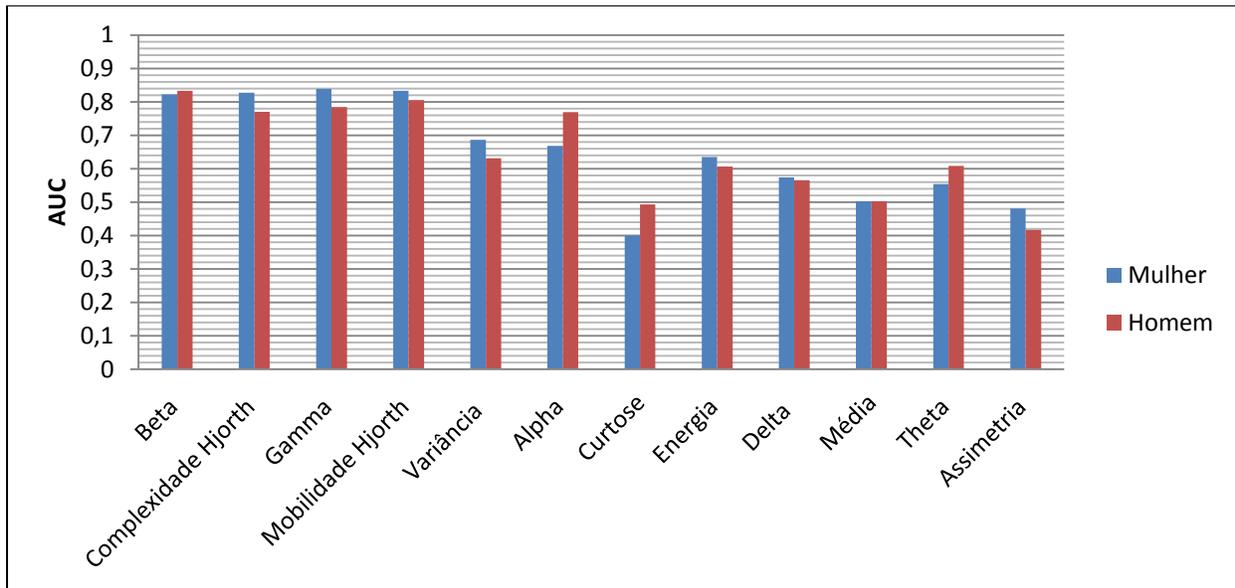


Figura 35: Detalhe das características referentes ao sexo e elétrico O1.

Como pode verificar-se para o sensor em causa as características obtiveram um melhor resultado, sendo que desta forma já foi possível obter um melhor resultado com um classificador, podendo assim alertar o utilizador para um estado de sonolência.

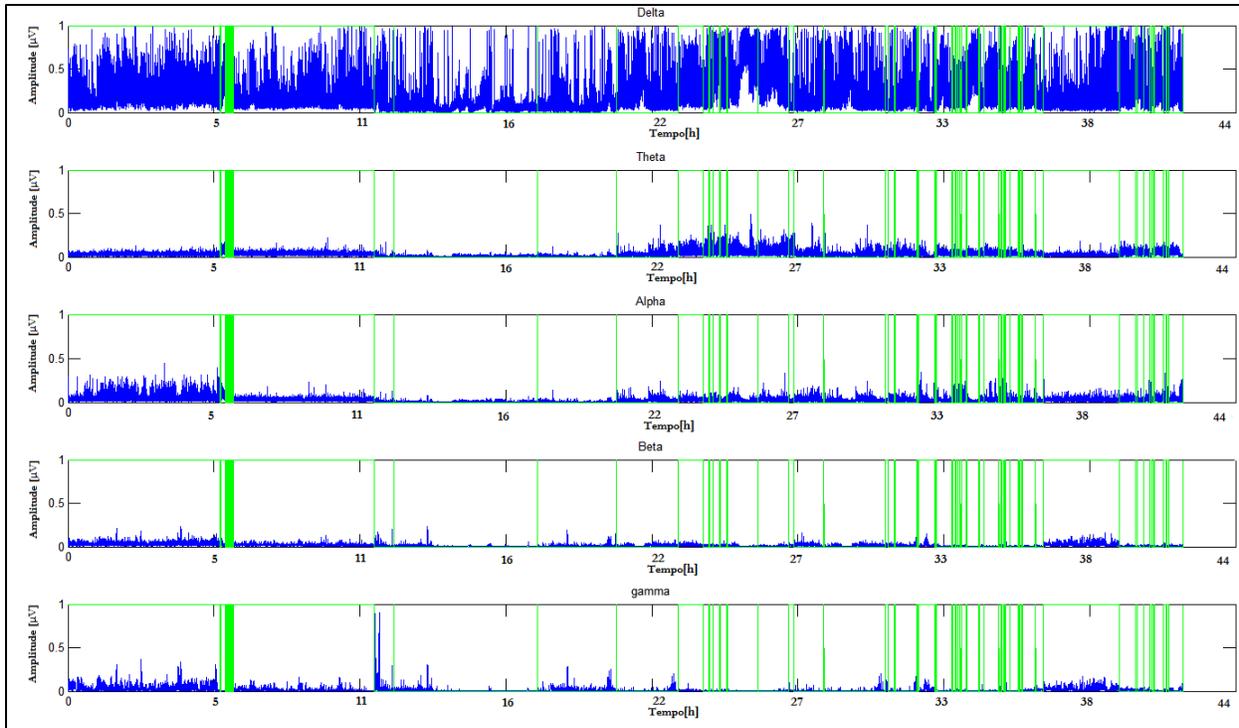


Figura 36: Evolução temporal das potências relativas nas diversas bandas para o elétrodo O1.

- **Elétrodo O2**

Para o elétrodo O2 espera-se que se aproxime também do O1 e que os resultados sejam bastante melhores relativamente aos elétrodos F4 e F3.

Tabela 27: Dados mulher elétrodo O2.

Característica	AUC
Beta	0,7648
Alpha	0,7040
Gamma	0,6932
Mobilidade Hjorth	0,6914
Complexidade Hjorth	0,6790
Variância	0,6623
Energia	0,6307
Theta	0,6074
Delta	0,6018
Assimetria	0,5418
Média	0,5027
Curtose	0,4737

Tabela 28: Dados homem elétrodo O2.

Característica	AUC
Beta	0,8196
Alpha	0,7473
Mobilidade Hjorth	0,7253
Gamma	0,7065
Complexidade Hjorth	0,6927
Variância	0,6190
Theta	0,6060
Energia	0,5983
Delta	0,5646
Curtose	0,5312
Média	0,5027
Assimetria	0,4425

Tabela 29: Dados elétrodo O2.

Característica	AUC
Beta	0,8436
Mobilidade Hjorth	0,7601
Gamma	0,7498
Alpha	0,7482
Complexidade Hjorth	0,7331
Variância	0,6052
Theta	0,5918
Energia	0,5793
Delta	0,5603
Curtose	0,5244
Média	0,5049
Assimetria	0,5021

Como pode verificar-se as características continuam a ser muito parecidas ao elétrodo apresentado anteriormente, mesmo os valores obtidos são muito próximos. A diferença entre os sexos não é muito discriminativa.

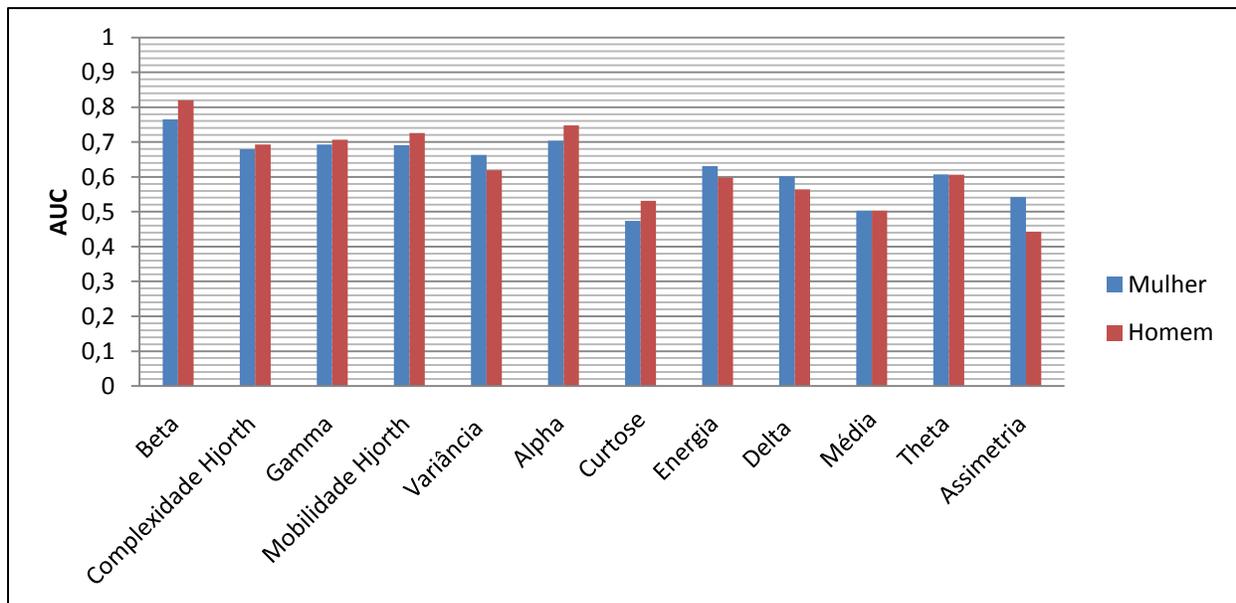


Figura 37: Características O2 relativas ao sexo.

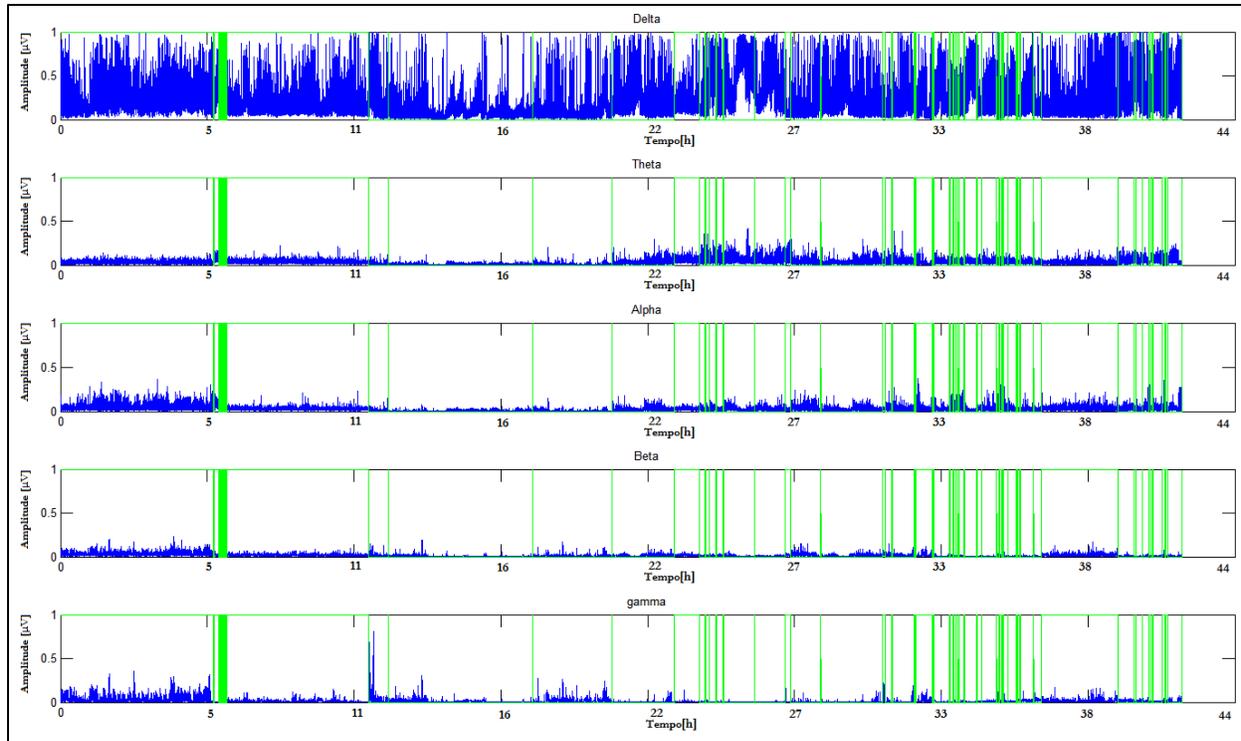
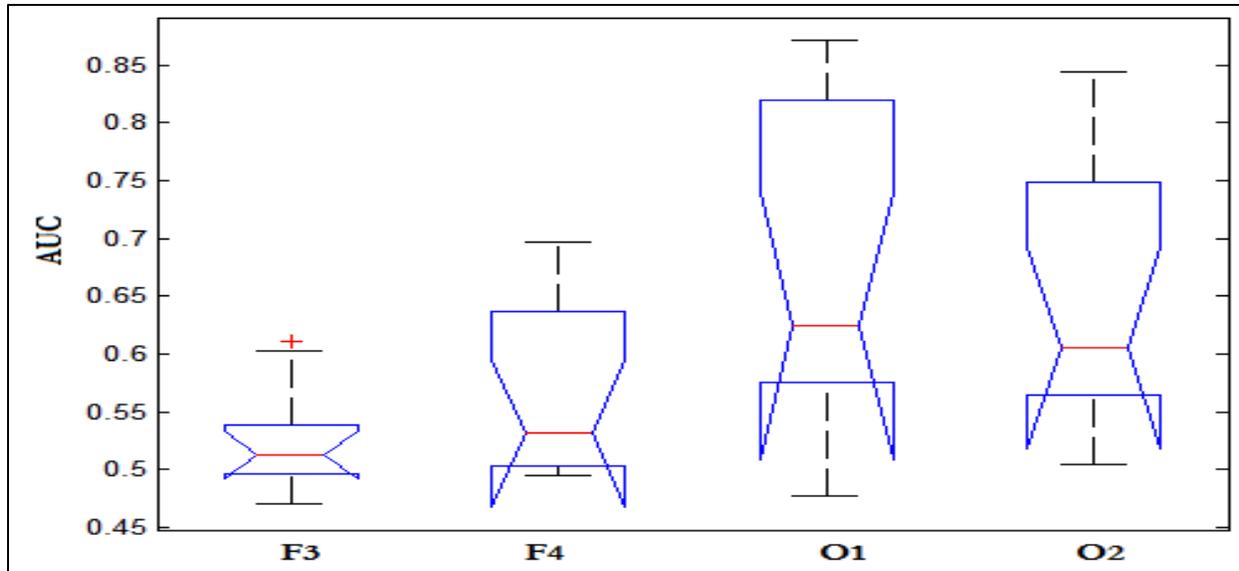


Figura 38: Evolução temporal das potências relativas nas diversas bandas para o elétrodo O2.

Os dados aqui recolhidos e apresentados são bastante semelhantes ao do elétrodo O1, podendo assim utilizar-se os dois para melhor classificar o estado de pré-sono pois podem muito bem complementar-se um ao outro, focando melhor a detecção correta do estado de sonolência.

- **Análise do efeito dos elétrodos**

Por forma a avaliar se a seleção de determinados elétrodos resulta em diferenças estatisticamente significativas na capacidade discriminatória das diferentes características, recorreu-se a uma análise usando a técnica Kruskal-Wallis. A figura seguinte mostra os resultados dessa análise.



Kruskal-Wallis ANOVA Table					
Source	SS	df	MS	Chi-sq	Prob>Chi-sq
Columns	2001.91	3	667.303	12.13	0.0069
Error	5093.09	40	127.327		
Total	7095	43			

Figura 39: Dados relativos aos eléctrodos a estudar e qual nos apresenta melhores resultados.

Como pode verificar-se, os eléctrodos O1 e O2 encontram-se um pouco mais destacados relativamente aos eléctrodos F3 e F4. Isto pode dever-se ao facto de os primeiros se encontrarem mais próximos da zona central do couro cabeludo e os eléctrodos F3 e F4 serem um pouco mais distantes da zona central. Existe uma grande significância nos resultados obtidos. Analisando o valor do *P-value* conclui-se que o teste de *Kruskal-Wallis* determinou que as diferenças observadas são estatisticamente significativas, mesmo considerando um nível de significância de 1%. De acordo com a Tabela 4 pode dizer-se que as diferenças são *muito significativas*.

Dada a baixa capacidade discriminativa das características relacionadas com os eléctrodos F3 e F4, e ambicionando a simplificação do problema, foram desde logo descartados os eléctrodos F3 e F4. Como o dispositivo móvel Android dispõe de poucos recursos, foi necessário otimizar de modo a tirar os melhores resultados com pouco processamento, não colocando em causa as capacidades de recolha e análise dos dados em tempo real.

- Análise do efeito das características

Relativamente às características, realizou-se da mesma maneira que anteriormente o teste de *Kruskal-Wallis*. Os resultados obtidos encontram-se descritos na Figura 40.

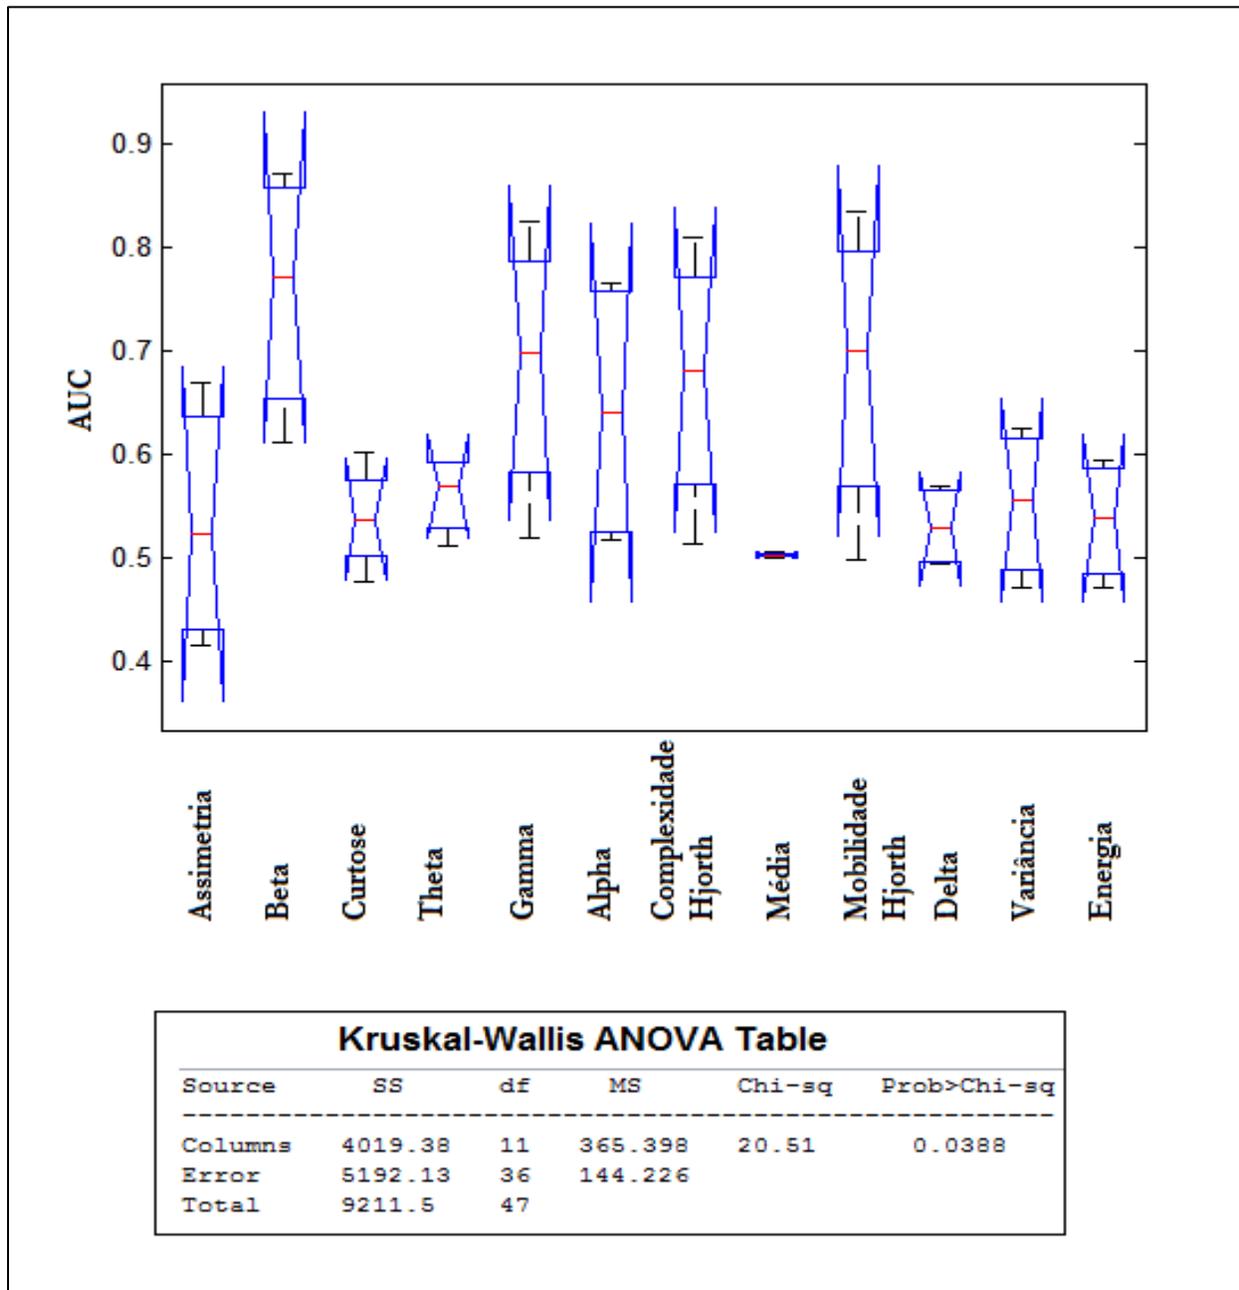


Figura 40: Valores finais de características, sendo apresentado também o máximo mínimo e médio.

Como pode verificar-se, a característica referente à potência relativa na banda Beta é a que melhores resultados nos apresenta. Analisando o *P value* pode concluir-se que existe uma diferença estatisticamente significativa, mas não muito. Ou seja, a escolha de uma determinada característica afeta a performance de classificação.

De um estudo mais pormenorizado das quatro melhores características obtidas, temos:

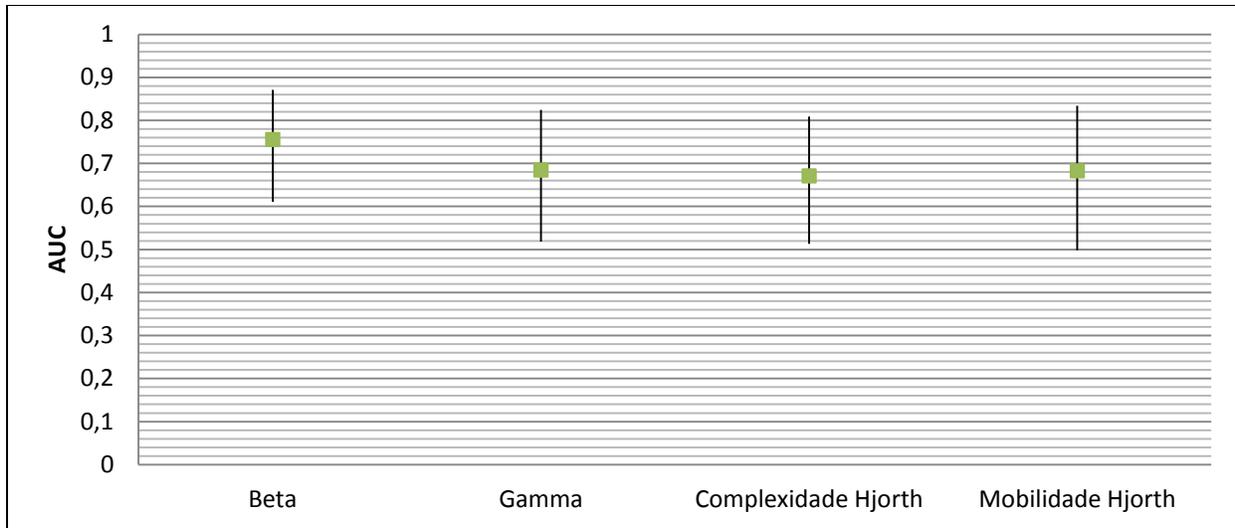


Figura 41: Resultados finais de junção de todos os valores das 4 melhores características.

Podemos ver que entre as quatro melhores características existe uma grande oscilação entre o valor mínimo e o valor máximo das mesmas, sendo que o valor máximo obtido em todas elas é superior a 0.8 o que é um bom resultado para o problema em causa.

- Análise do efeito do sexo

Embora exista uma tendência para a obtenção de uma melhor capacidade discriminativa em indivíduos do sexo feminino, a análise de *Kruskal-Wallis* não encontrou diferenças muito significativas, como mostra a Figura 42. Este facto indica que podemos considerar uma abordagem geral para ambos os sexos.

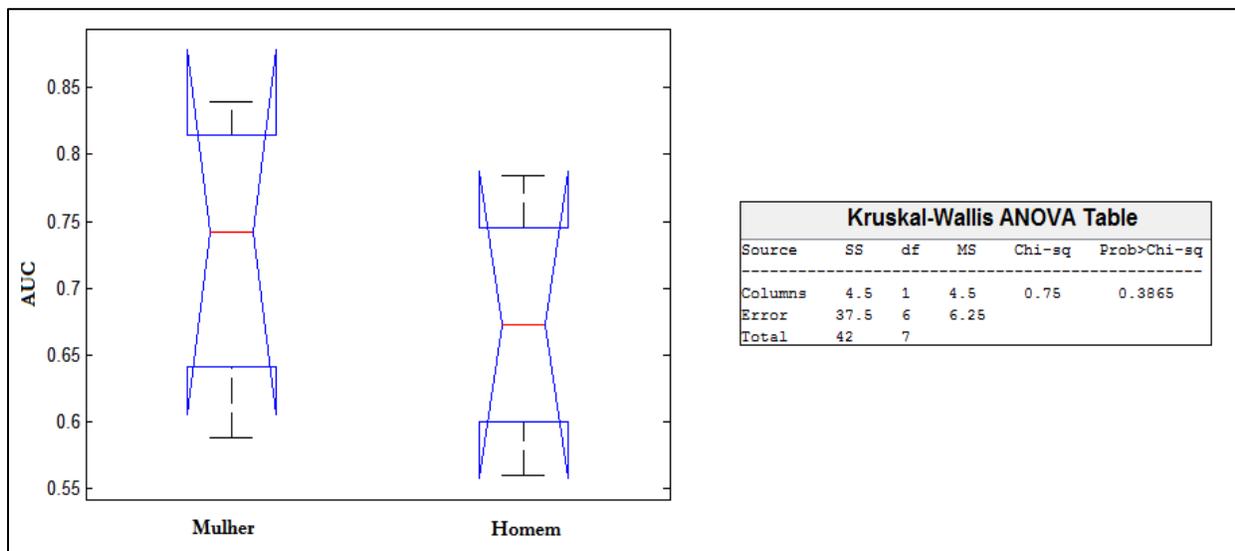


Figura 42: Análise relativamente ao sexo.

- **Análise do efeito da idade**

Foi realizado um estudo para verificar se o efeito da idade resultava em diferenças estatisticamente significativas. Para isso os indivíduos foram divididos em três patamares, sendo eles:

- Menores de 18 anos;
- Entre 18 e 30 anos;
- Maiores de 30 anos.

Nesta análise foram usadas somente as características relacionadas com os elétrodos O1 e O2, uma vez que já tínhamos verificado que os melhores resultados advêm dos mesmos. O número de pacientes em estudo é de três com idades menor que dezoito anos, três com idades entre dezoito e trinta anos e dois maiores de trinta anos, dos grupos referidos anteriormente.

Para idades inferiores a 18 anos obtivemos os seguintes resultados:

Tabela 30: Eléctrodo O1.

Característica	AUC
Beta	0,8967
Mobilidade Hjorth	0,8534
Gamma	0,8521
Complexidade Hjorth	0,8413
Alpha	0,7281
Curtose	0,5613
Média	0,5009
Assimetria	0,3829
Theta	0,2887
Energia	0,2582
Variância	0,2510
Delta	0,2400

Tabela 31: Eléctrodo O2.

Característica	AUC
Beta	0,8923
Gamma	0,8838
Complexidade Hjorth	0,8773
Mobilidade Hjorth	0,8719
Alpha	0,6935
Curtose	0,5482
Média	0,5048
Assimetria	0,3875
Energia	0,2870
Variância	0,2829
Delta	0,2769
Theta	0,2766

Para idades entre os 18 e os 30 anos obtivemos:

Tabela 32: Eléctrodo O1.

Característica	AUC
Gamma	0,8239
Complexidade Hjorth	0,8163
Mobilidade Hjorth	0,8092
Beta	0,7529
Alpha	0,5481
Média	0,5072
Assimetria	0,5038
Curtose	0,4300
Energia	0,4102
Variância	0,3956
Delta	0,3451
Theta	0,2743

Tabela 33: Eléctrodo O2.

Característica	AUC
Gamma	0,6972
Complexidade Hjorth	0,6875
Beta	0,6727
Mobilidade Hjorth	0,6682
Alpha	0,5694
Média	0,5081
Assimetria	0,4972
Curtose	0,4403
Energia	0,4215
Variância	0,4057
Delta	0,3754
Theta	0,3327

Para idades superiores a 30 anos obtivemos os seguintes resultados:

Tabela 34: Eléctrodo O1.

Característica	AUC
Variância	0,8553
Energia	0,8158
Mobilidade Hjorth	0,8112
Gamma	0,7968
Complexidade Hjorth	0,7914
Beta	0,6724
Delta	0,5895
Theta	0,5358
Alpha	0,5081
Média	0,5043
Assimetria	0,4132
Curtose	0,3701

Tabela 35: Eléctrodo O2.

Característica	AUC
Energia	0,8371
Variância	0,8141
Gamma	0,6959
Delta	0,6957
Mobilidade Hjorth	0,6876
Complexidade Hjorth	0,6862
Beta	0,6727
Theta	0,6254
Alpha	0,5998
Média	0,5004
Assimetria	0,4856
Curtose	0,4499

O estudo demonstrou que as idades resultam em diferenças estatisticamente significativas em termos nos resultados obtidos, como mostra as figuras seguintes. Nas idades inferiores a 18 anos, a capacidade de deteção é superior às outras.

Para o eléctrodo O1 obtivemos os seguintes resultados:

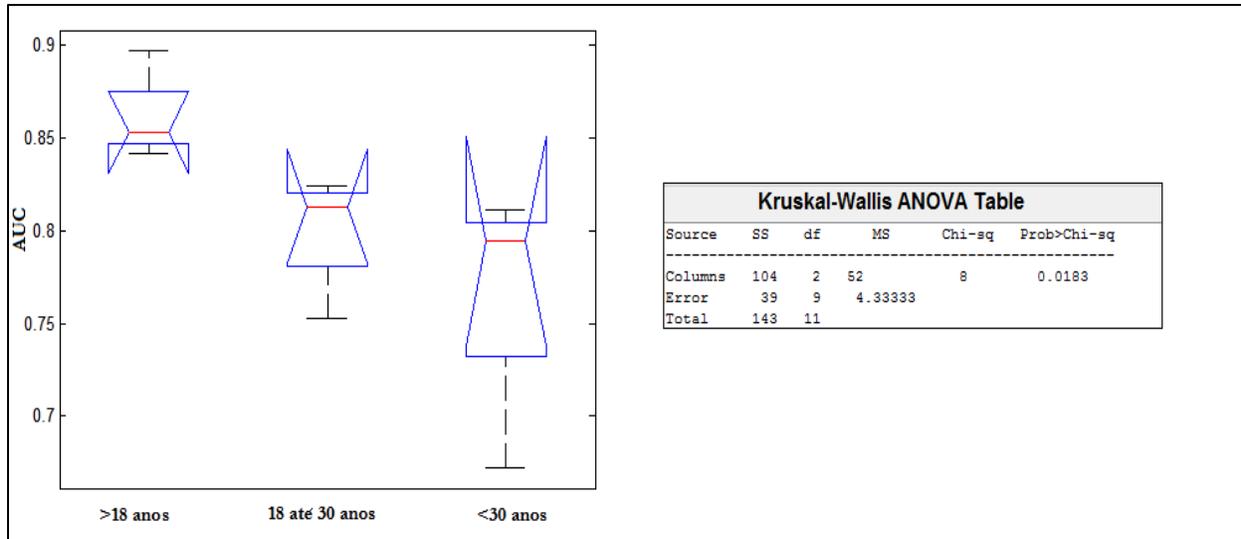


Figura 43: Dados relativos a idades menores que dezoito anos, entre dezoito e trinta anos e por fim idades superiores a trinta anos. Senso o O1 o eléctrodo em análise.

Já para o eléctrodo O2, os resultados pouco alteram:

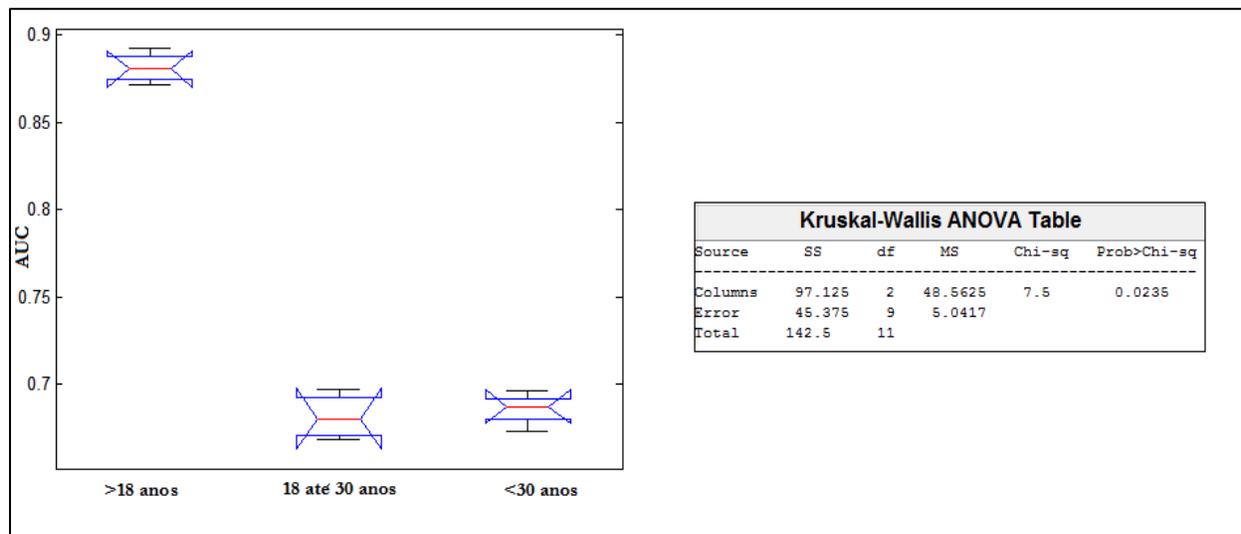


Figura 44: Dados relativos a idades menores que dezoito anos, entre dezoito e trinta anos e por fim idades superiores a trinta anos neste caso para o eléctrodo O2.

Verificou-se também que a diferença entre o eléctrodo O1 e O2 é mínima, o que nos leva a concluir que são ambos os eléctrodos credíveis para a recolha de dados e deteção de sonolência.

- **Resumo Geral**

Podemos concluir através de todos os resultados apresentados anteriormente que as características que melhor caracterizam o nosso problema são:

- Potência relativa na banda Gamma
- Complexidade Hjorth
- Mobilidade Hjorth
- Potência relativa na banda Beta

Assim, foi possível descartar as outras características e prosseguir para a parte da classificação com apenas a análise destas características uma vez que a sua sensibilidade/especificidade é muito maior em todos os casos estudados. Considerando somente estas quatro características e refazendo a análise em função dos diferentes eléctrodos, podemos constatar, como se mostra na Figura 45, que de facto os eléctrodos O1 e O2 são os mais apropriados.

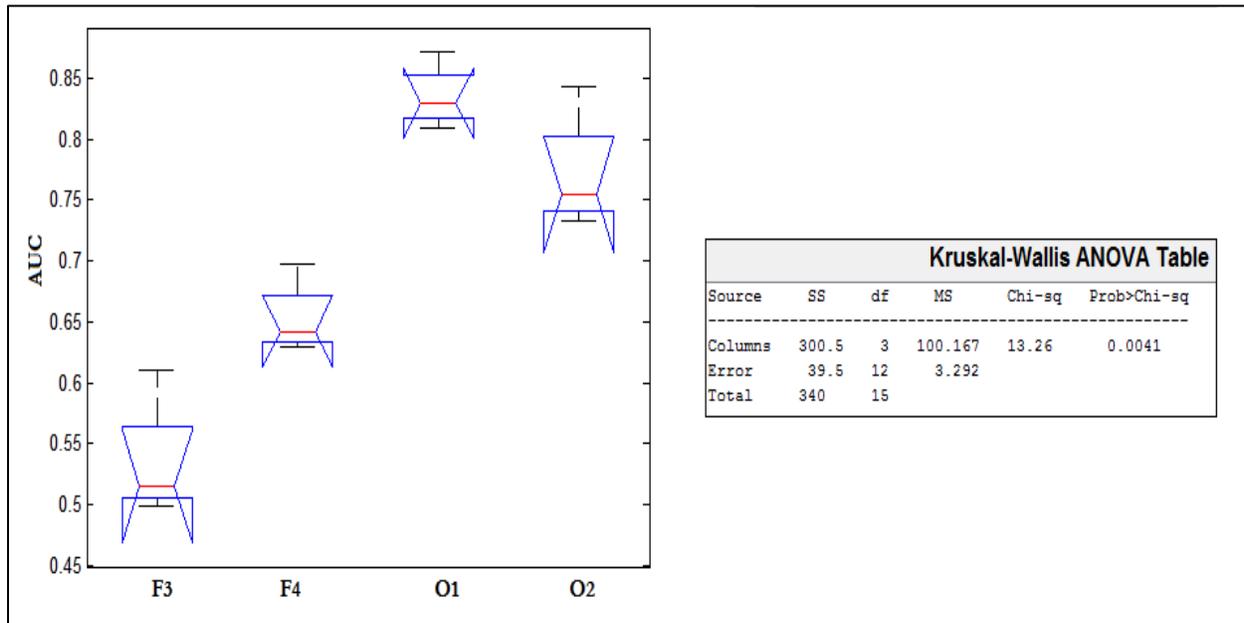


Figura 45: Análise dos eléctrodos em estudo com as melhores características.

Em suma, os resultados apresentados, para a fase de classificação foram consideradas somente as quatro características referidas anteriormente e os eléctrodos O1 e O2.

4.3 Classificadores

Para conseguir obter a melhor performance em termos de classificação, tivemos de analisar os vários classificadores apresentados na secção 2.4 para assim maximizarmos a performance de deteção do estado de sonolência.

Inicialmente começámos por implementar um classificador linear, classificador esse que se veio a verificar que não seria uma boa opção pois o mesmo não nos daria um acerto muito grande. Sendo que no estudo preliminar elaborado (Secção 4.1) com os elétrodos centrais Pz-Oz e com um simples limiar de decisão se atingiu taxas de acerto próximas de 100%. Os diversos passos da etapa de classificação encontram-se apresentados na Figura 46.

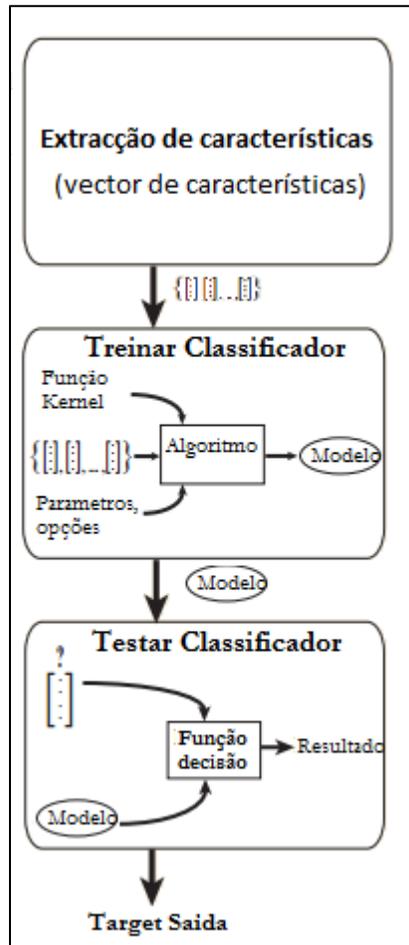


Figura 46: Passos seguidos para o desenvolvimento dos classificadores.

Para cada parametrização dos diversos classificadores foram levados a cabo 10 fases de treino e teste, envolvendo uma seleção aleatória dos padrões de treino e teste. Esta abordagem resulta numa melhor avaliação da capacidade de classificação e maximiza também a probabilidade de escolha da parametrização mais adequada. Em cada, fase 70% dos padrões foram usados para treino e 30% para teste.

As características usadas foram as potências relativas na banda Beta e Gamma, extraídas de O1.

4.3.1 Bayes

Então passámos para análise do classificador bayesiano que nos veio a dar os seguintes resultados:

Tabela 36: Resultados do classificador bayesiano.

	Runs	Sensibilidade	Especificidade	Precisão	Fall-out	Erro
Bayes	1	64,9	90,9	89,0	0,09	19,9
	2	69,1	91,2	86,8	0,08	20,3
	3	70,1	90,2	87,7	0,09	19,8
	4	70,2	90,7	88,6	0,09	19,7
	5	68,7	91,3	89,9	0,08	20,6
	6	69,0	91,2	89,9	0,08	20,5
	7	68,9	91,2	89,6	0,08	20,4
	8	69,4	91,1	89,2	0,08	19,9
	9	69,4	91,3	89,6	0,08	19,9
	10	69,1	91,2	89,4	0,08	20,1
	Media	68,9	91,0	89,3	0,08	20,1
	Desvio Padrão	0,014	0,003	0,006	0,003	0,003

Através de todos os parâmetros de saída verificou-se que os erros são da ordem dos 20% sendo que a taxa de acerto é de 80%. Na figura abaixo encontra-se representada a distribuição dos diversos padrões, bem como a superfície de decisão associada ao melhor classificador de Bayes.

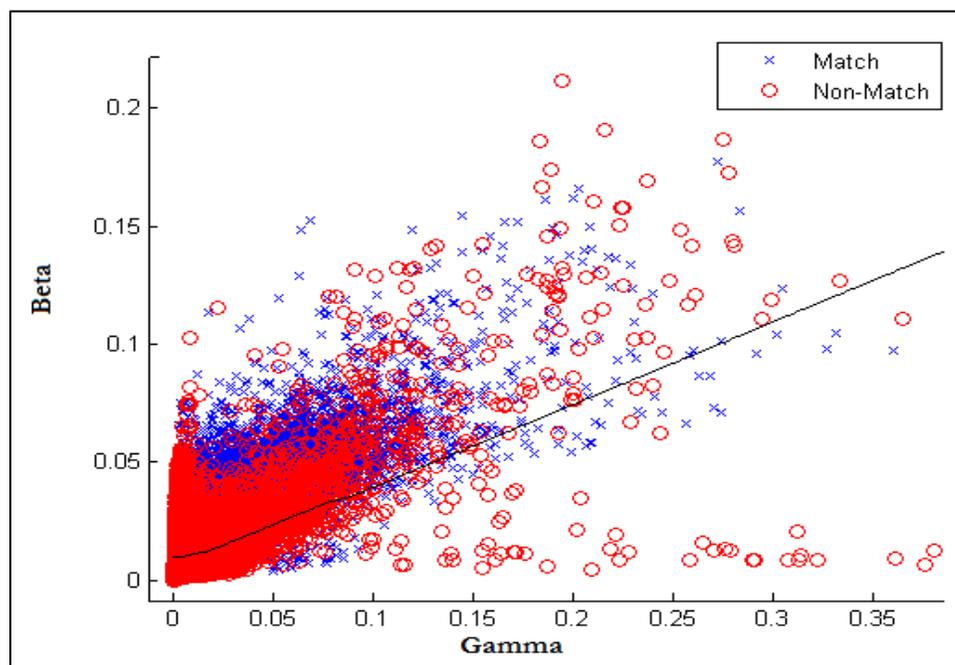


Figura 47: Resultados obtidos pelo classificador bayes para duas características.

Com estes resultados pudemos verificar que seria necessário recorrer a outro classificador que nos pudesse melhorar os nossos resultados.

4.3.2 Redes Neurais Artificial

De seguida foi analisada uma rede neuronal através de uma da Toolbox de redes neurais do Matlab (Neural Network Toolbox™). Para esta começamos por definir a rede, seguindo os seguintes critérios:

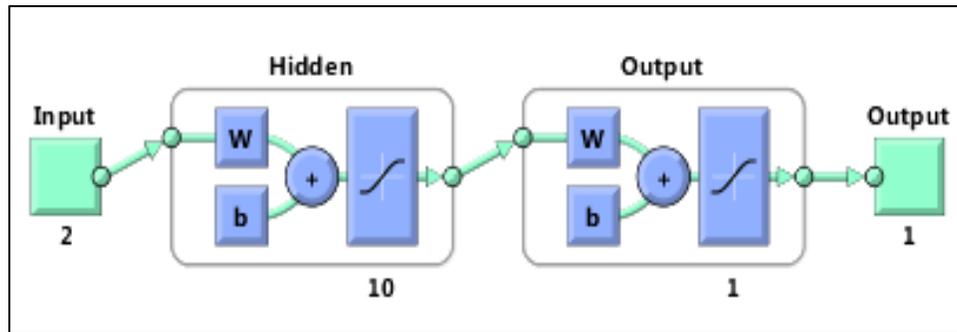


Figura 48: Rede neuronal com duas entradas e uma saída.

Assim sendo, demos as duas melhores características obtidas (Beta e Gamma) com os seguintes dados para um treino de 70% e um teste de 30% relativamente aos dados que dispomos:

Runs	AUC (%)	Erro
1	79,7	20,3
2	79,5	20,5
3	79,6	20,4
4	80,4	19,6
5	80,2	19,8
6	78,7	21,3
7	79,3	20,7
8	79,9	20,1
9	80,2	19,8
10	80,5	19,5
Media	79,8	20,2
Desvio Padrão	0,53	0,53

Tabela 37: Resultados da toolbox da rede neuronal para a rede apresentada.

Como se verifica o erro continua em cerca de 20%, sendo que se mantem como o classificador anteriormente apresentado.

Através da *Toolbox* usada foi possível verificar e analisar a melhor performance de validação, as curvas de ROC das várias fases de análise do classificador.

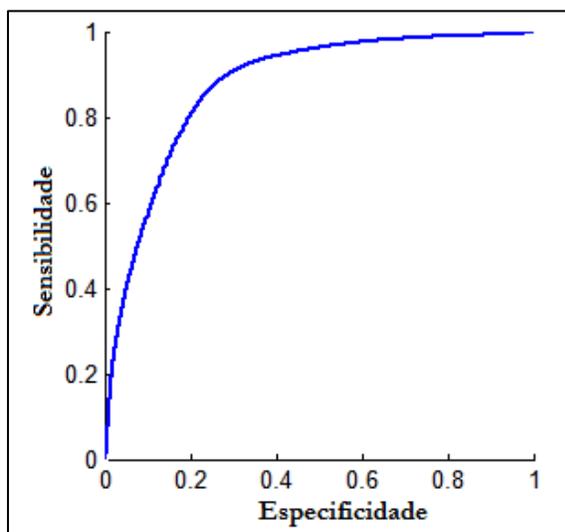


Figura 49: Curva ROC para ANN.

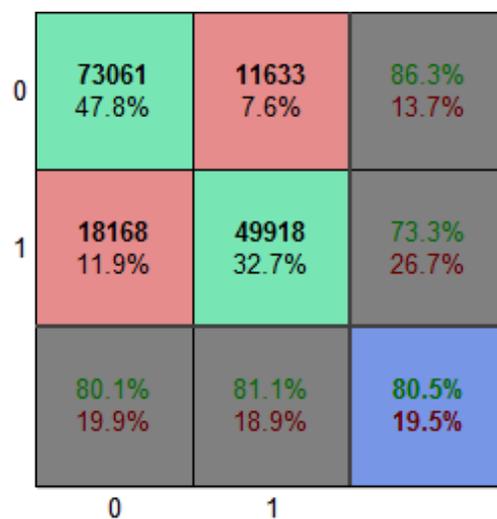


Figura 50: Informação curva ROC, como apresentado na secção 3.6.1.

Este exemplo aqui demonstrado e referente ao Run=10 da rede ANN, como se pode verificar o erro encontra-se com cerca de 19,5%, chegando a uma análise que este erro será um erro que será difícil de ultrapassar por classificadores bayes e RNA. Podemos pela Figura 50 visualizar todos os valores que foram corretamente classificados como vice-versa, estando os mesmos representados e vermelho e os outros a verde.

4.3.3 K-Vizinhos mais próximos

Foi também analisado o algoritmo KNN do qual o mesmo inicialmente foi necessário escolher o melhor K, para isso corremos o algoritmo 10 vezes para cada valor de K e obtivemos os seguintes resultados:

Tabela 38: Erro (%) obtido para os diferentes valores de K.

Runs	K=5	K=6	K=7	K=8	K=9	K=10
1	13,2	13,2	12,9	12,7	12,6	12,5
2	13,2	13,0	12,7	12,6	12,5	12,4
3	13,2	13,0	12,7	12,7	12,5	12,5
4	13,2	13,2	12,8	12,6	12,5	12,5
5	13,2	13,0	12,8	12,7	12,5	12,5
6	13,3	13,3	12,9	12,4	12,4	12,3
7	13,3	13,1	12,7	12,6	12,5	12,3
8	13,4	13,0	12,8	12,7	12,7	12,5
9	13,2	13,1	12,9	12,5	12,3	12,2
10	13,6	13,2	12,8	12,3	12,6	12,3
Media	13,3	13,1	12,8	12,6	12,5	12,4
Desvio Padrão	0,12	0,09	0,07	0,11	0,10	0,11

Runs	K=11	K=12	K=13	K=14	K=15
1	12,5	12,4	12,4	12,3	12,3
2	12,4	12,3	12,3	12,3	12,2
3	12,5	12,4	12,3	12,3	12,2
4	12,5	12,4	12,4	12,3	12,3
5	12,4	12,3	12,4	12,2	12,2
6	12,3	12,4	12,3	12,3	12,2
7	12,4	12,4	12,4	12,3	12,3
8	12,4	12,4	12,3	12,2	12,2
9	12,5	12,5	12,4	12,3	12,4
10	12,4	12,5	12,3	12,2	12,7
Media	12,4	12,4	12,4	12,3	12,3
Desvio Padrão	0,07	0,06	0,06	0,04	0,06

Como pode verificar-se, os resultados obtidos para o valor de K são bastante semelhantes a partir de K=7, pelo que considerámos não ser necessário efetuar uma análise para valores superiores, uma vez que o erro já era bastante baixo. Assim, prosseguiu-se para a análise mais detalhada dos valores para os K de 7 até 11. Os resultados obtidos em relação aos K com apenas um run foram:

Tabela 39: Resultado do classificador K-NN para os diferentes valores de K.

	Sensibilidade	Especificidade	Precisão	Fall-out	Erro Teste
K=7	88,6	82,8	89,9	11,3	12,9
K=8	88,9	83,2	90,1	11,0	12,6
K=9	85,1	89,1	83,4	10,8	12,4
K=10	89,1	83,6	90,5	10,8	12,2
K=11	85,5	88,9	83,4	11,0	12,4

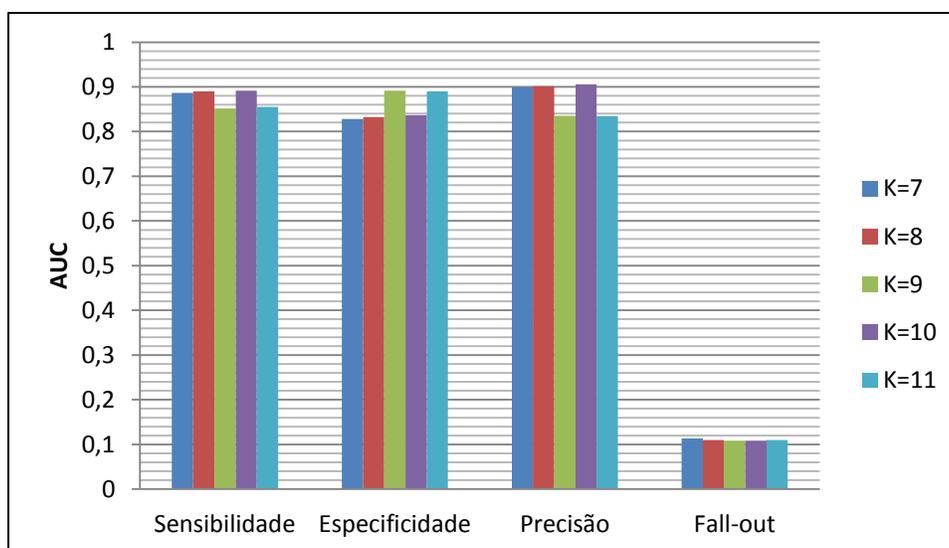


Figura 51: Análise pormenorizada dos valores de K.

Como pode verificar-se pela Tabela 38 e pela Figura 51 pode dizer-se que $K=10$ é uma boa escolha. No entanto, podemos verificar que qualquer um dos valores K também seria uma boa escolha. Comparando o erro em treino e teste para os vários valores de K , obtivemos os seguintes resultados apresentados na figura seguinte.

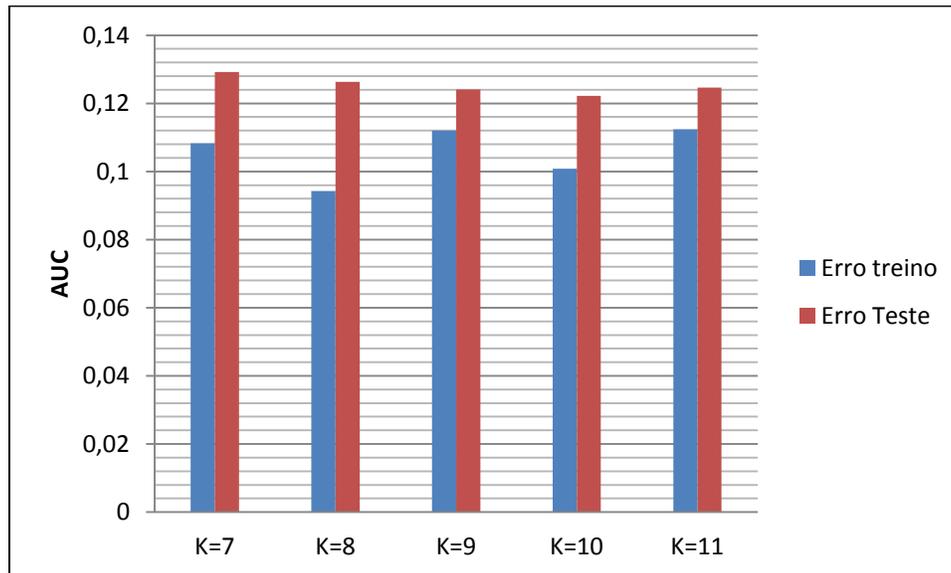


Figura 52: Erros associados ao valor de K .

Como pode verificar-se, os erros no conjunto de teste vão diminuindo até $K=10$, sendo que de seguida os mesmos voltam a aumentar, piorando assim os resultados. Analisados estes resultados pode concluir-se que deve ser usado o valor de $K=10$ para uma análise mais pormenorizada do nosso classificador.

A Figura 53 apresenta as superfícies de decisão definidas pelo algoritmo KNN com $K=10$. Pode verificar-se que o mesmo permite a definição de superfícies bem irregulares devido ao facto de as mesmas serem simplesmente definidas pela classe dos 10 vizinhos mais próximos a cada padrão.

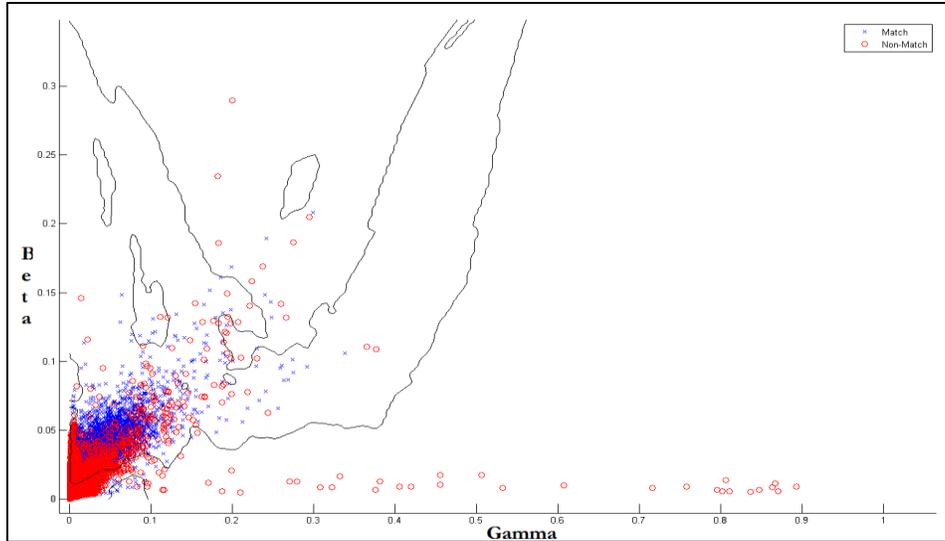


Figura 53: Distribuição dos padrões de teste e superfícies de decisão definidas pelo algoritmo KNN com $K=10$.

4.3.4 Máquina de vetor de suporte (SVM)

Visto os valores obtidos pelo classificador KNN serem muito bons, verificamos se o classificador SVM nos podia trazer ainda alguma melhoria relativamente ao classificador KNN.

De forma a melhorar o desempenho do classificador, foi necessário proceder manualmente a algumas configurações do classificador e inicialmente foi descobrir o melhor valor de parâmetro C (Soft Margin), como apresenta a Figura 54.

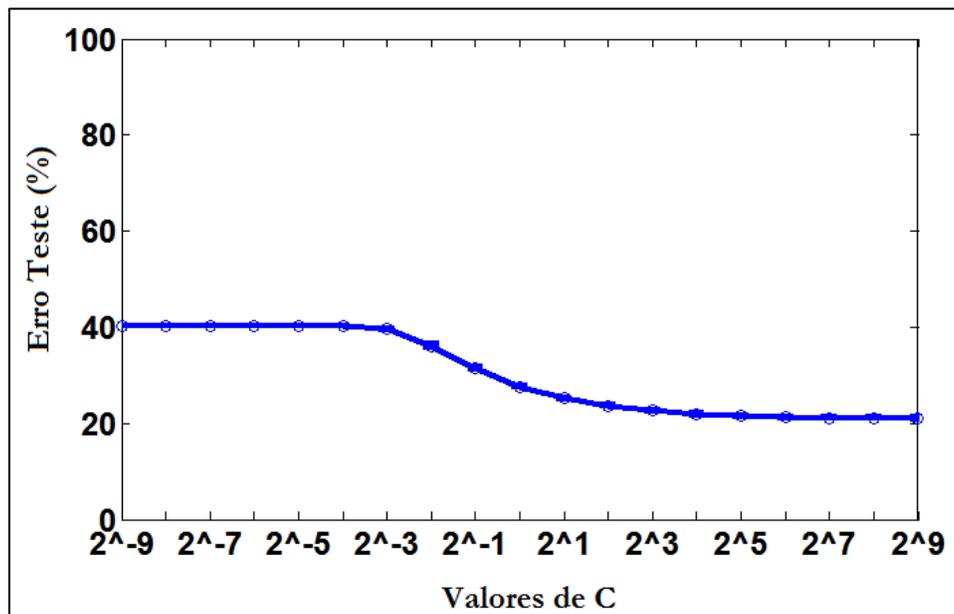


Figura 54: Verificação do melhor valor de C .

Para cada valor de C , foram elaborados 10 testes, sendo no final feita a sua média e é esse valor apresentados na Figura 54. Como se pode verificar na Figura 54 o melhor valor foi para um valor de $C=2^9$, verificando-se que o erro não passa abaixo do 20% o que não melhora em nada relativamente aos outros classificadores já usados.

Verificou-se de seguida a análise da curva ROC assim como da sua classificação.

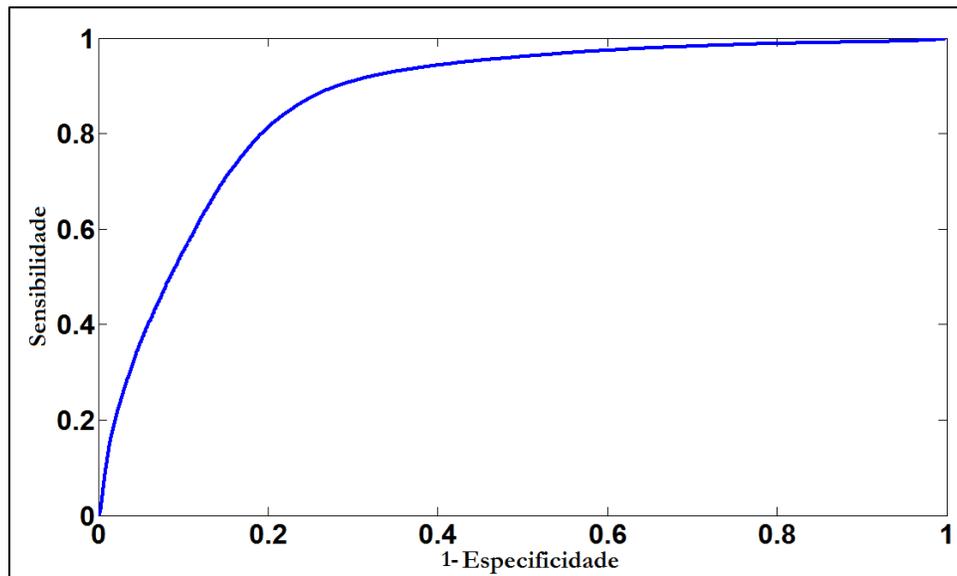


Figura 55: Curva ROC para o classificador SVM

Como já sabemos o valor de C que melhores resultados nos pode apresentar, fizemos então uma análise mais detalhada do classificador e o resultante é apresentado na Figura 56.

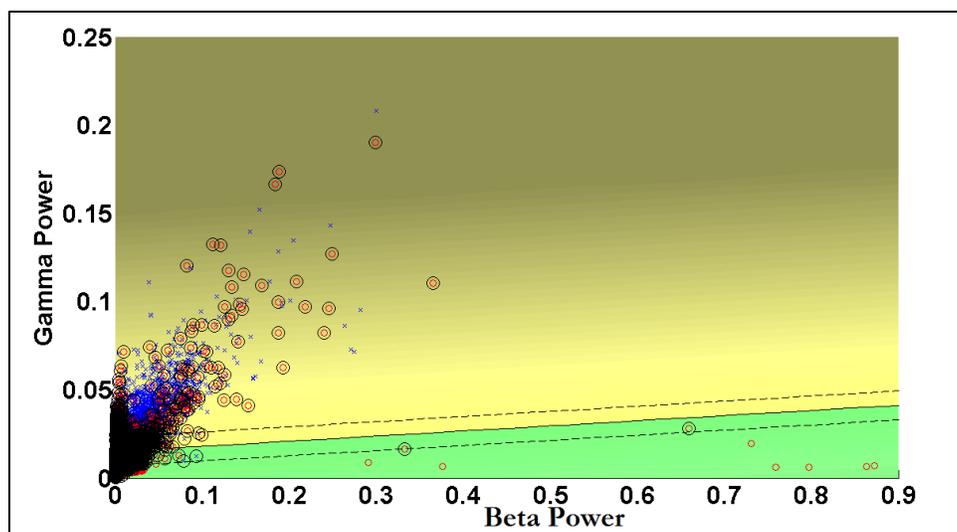


Figura 56: Classificadores SVM para o valor de $C=9$.

Como se pode verificar existe uma grande sobreposição dos padrões, sendo que as características consideradas são as que melhores resultados nos apresentam em termos de classificação de sono.

4.3.5 Resumo

Como se pode verificar a maioria dos classificadores apresenta um erro de aproximadamente 20%, sendo que para o classificador KNN o mesmo fica muito a baixo desse erro, sendo apenas de 12%. Este facto deve-se à capacidade do KNN permitir o desenvolvimento de superfícies de decisão não lineares, que permite a obtenção de um erro baixo em padrões muito sobrepostos.

Ainda relativamente a toda esta análise, depois de inicialmente termos efetuado a primeira análise, sempre se pensou que seria fácil a análise do estado de pré-sono através do dispositivo *Emotiv*, mas o mesmo não se veio a verificar. Pode dizer-se que para as condições apresentadas no estudo preliminar seriam as ideais. No entanto, nos novos dados fornecidos pelos CHUC, veio a verificar-se que não seria tão linear a deteção do estado de pré-sono. Caso fosse possível ter um maior número de indivíduos, talvez fosse possível melhorar também um pouco este erro.

4.4 Aplicação móvel para classificação de estados de sonolência em tempo-real

A aplicação desenvolvida dispõe de vários interfaces de visualização, podendo dar vários tipos de informação ao utilizador. Assim, mesmo que sejam utilizadores sem conhecimento na área, podem interagir com o sistema.

Inicialmente desenvolvemos a interface de entrada, que apresentamos de seguida., Esta interface necessita de permissão para efetuar conexão com o dispositivo *Emotiv* para assim poder recolher os sinais do mesmo e efetuar a respetiva análise.

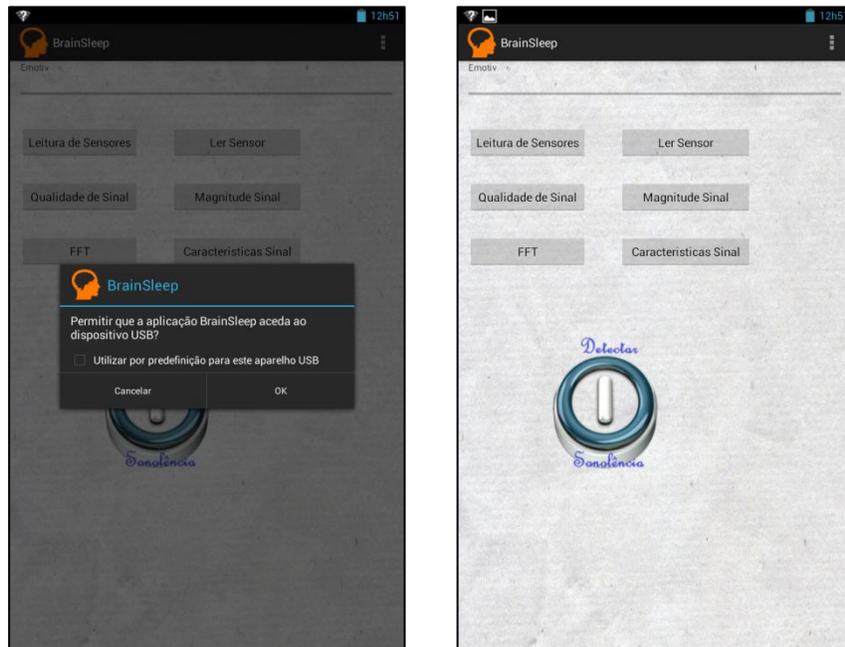


Figura 57: Ecrãs iniciais.

Assim que é permitida a conexão entre os dispositivos, podemos então efetuar uma análise dos vários elétrodos e da informação da qualidade do sinal e do valor das suas características. Todas as opções que estão disponíveis apenas vêm complementar o estudo e análise para a detecção do estado de pré-sono, podendo assim alertar o utilizador através de emissão sonora e visual.

Na Figura 58 podemos verificar os valores que estão a ser recolhidos pelo *Emotiv*, podendo verificar-se todos os dados referentes aos diferentes elétrodo, já na Figura 59 pode escolher-se o elétrodo desejado.

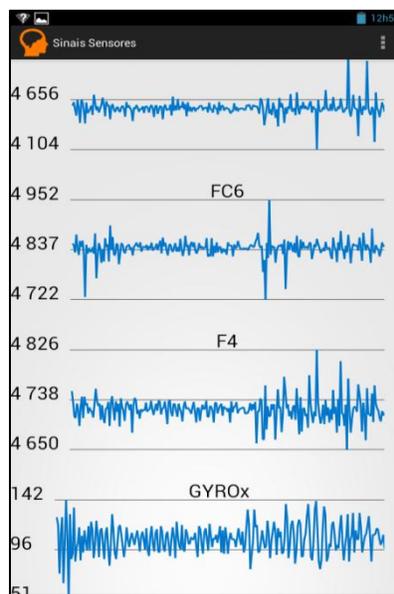


Figura 58: Janela da aplicação que mostra os sinais dos elétrodos e giroscópios .

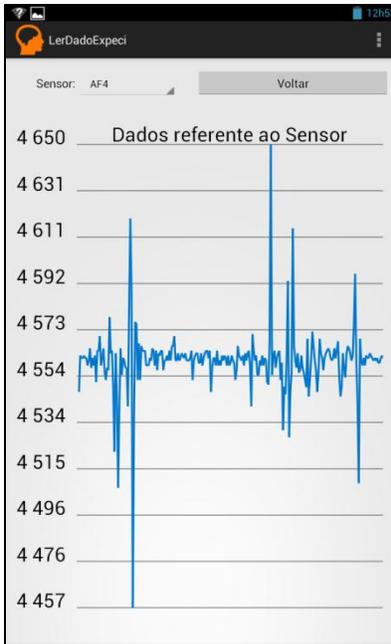


Figura 59: Dados de um eléctrodo em específico.

Foi necessário verificar também a conectividade, isto é, a impedância eléctrica de contacto, entre o eléctrodo e o coro cabeludo de forma a que os valores lidos pelo *Emotiv* estivessem o menos contaminados possível por ruído. Para isso, foi criado um interface onde é apresentado para cada eléctrodo a qualidade da conexão através de um código de cores: vermelho representa uma péssima conexão, laranja uma conexão mediana e verde uma boa conexão.

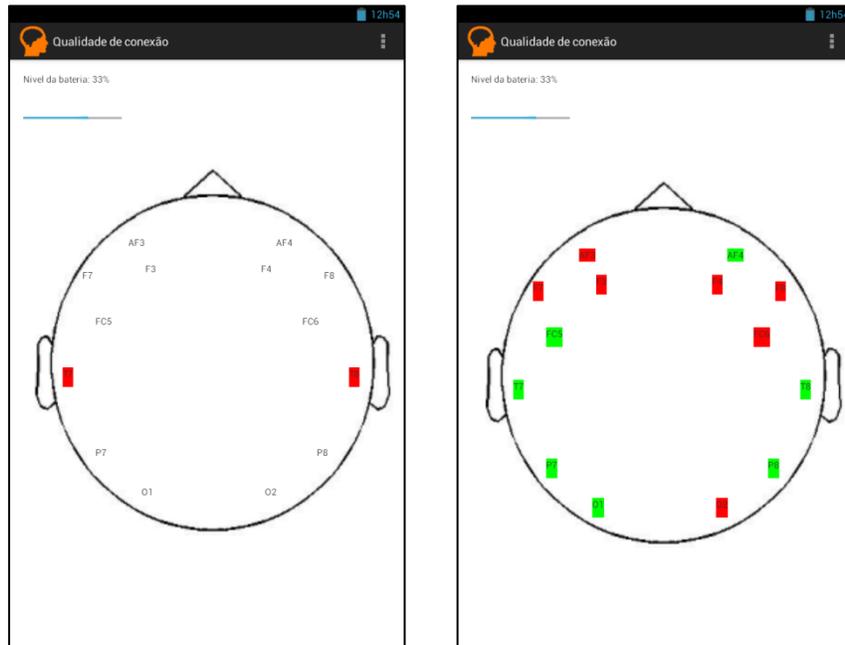


Figura 60: Qualidade Signal.

O interface anterior também apresenta o estado da bateria, sendo o mesmo apresentado no canto superior esquerdo.

Estes ecrãs, que podem encontrar-se na aplicação, podem apresentar informação muito importante para os utilizadores, sendo que para entender esta informação o utilizador tem que ter alguns conhecimentos matemáticos e de processamento de sinal. Com esses conhecimentos os utilizadores podem obter varias informações dos seus sinais EEG em tempo real, podendo assim verificar que algumas ações tomadas pelos mesmos têm consequências.

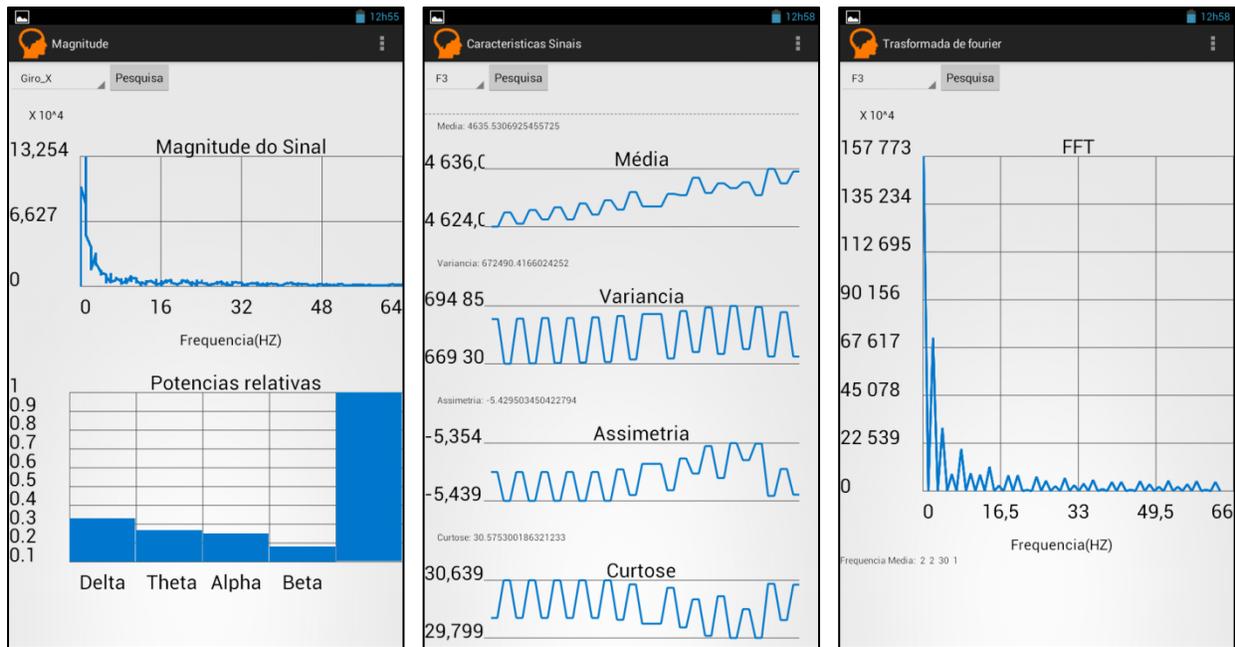


Figura 61: Janelas da aplicação que mostram as características extraídas do EEG.

Podemos ter acesso à informação das características dos sinais apresentadas anteriormente, tais como a média, variância, assimetria, entre outras.

Capítulo 5

Conclusões

Trabalho Realizado

O estágio para o primeiro semestre tinha como objetivo a compreensão dos problemas que poderiam surgir aquando da execução e implementação do *software* para os dispositivos disponibilizados. Foi necessário efetuar um estudo do *hardware Emotiv*, uma vez que foi este o dispositivo que nos forneceu a informação a analisar. Tivemos de fazer, também, um estudo dos dispositivos com sistema operativo Android, capazes de uma interligação via USB com o dispositivo *Human Interface Devices* (HID). Estes dois estudos foram fundamentais, pois existia um risco para a execução do projeto, uma vez que não existe nada desenvolvido em Android para o *Emotiv*. Seguidamente, fizemos um levantamento e elaborou-se um estudo em torno dos métodos já utilizados nos dias de hoje para efetuar a análise dos vários estados do sono. Assim, através do estudo efetuado no estado da arte, encontraram-se soluções já utilizadas no campo da detecção de estados de sonolência em indivíduos. Para se conseguir pôr em prática a detecção do estado de sonolência de um indivíduo, foi também necessário estudar as características do EEG bem como dos algoritmos de classificação.

Durante este estudo, foi também iniciado o desenvolvimento de um *software* para aquisição dos sinais provenientes do dispositivo móvel *Emotiv*, para posteriormente os mesmos serem apresentados no dispositivo Android. Foi necessário desenvolver todo o *software* para a comunicação e receção dos valores dos sinais adquiridos dos elétrodos. Assim que esses resultados foram obtidos, passámos para uma análise mais pormenorizada de cada elétrodo e dos valores por ele lidos, calculando-se as potências relativas nas diversas bandas.

No segundo semestre procedeu-se à recolha, à análise e à classificação dos indivíduos em estudo, assim como à validação de todo o *software* desenvolvido. Foram desenvolvidos novos módulos em falta para se conseguir uma análise e recolha dos dados, bem como a sua classificação. Devido às capacidades e limitações do *hardware* foi necessário proceder a um estudo de elétrodos para a recolha de dados e das características a extrair dos mesmos para serem classificados e podermos chegar à detecção dos estados pelo dispositivo móvel Android. Os dados constituíram o maior problema uma vez que os mesmos tiveram que ser primeiramente analisados por especialistas para depois poderem ser analisados neste projeto.

Em suma, foi desenvolvido todo o *software* que permite a ligação entre o *Emotiv* e o dispositivo Android e que permitiu efetuar a detecção do estado de pré-sono. De referir, que este *software* não existia e foi totalmente desenvolvido de raiz. No primeiro semestre todas as metas e objetivos que estavam propostos foram cumpridos. Já no segundo semestre o mesmo não aconteceu devido a alguns riscos detetados no início do estágio, o que levou ao atraso da entrega.

Reflexão e principais obstáculos

No decorrer deste estágio foram identificados vários obstáculos, desde logo a conexão do *Emotiv* com o dispositivo Android, sendo que aquele não funciona em todos os dispositivos móveis. Para resolver esse problema tivemos que recorrer a um dispositivo com capacidades de conexão com o *Emotiv*. Os dados do *Emotiv* encontravam-se encriptados e só existia forma em linguagem C para se descriptar, o que foi necessário proceder a todo esse estudo, no qual foram aprofundados os conhecimentos relativamente ao *hardware*.

De seguida existiu um outro obstáculo e este sim foi um obstáculo que não dependia apenas de nós para se poder chegar a uma conclusão final dentro dos prazos esperados. Este era relativo aos dados, pois seria necessário ter alguém (especialista na área) que pudesse proceder à classificação manual dos dados para posteriormente serem analisados, o que levou algum tempo para a obtenção dos mesmos e por sua vez atrasando a sua análise. Estando os mesmos etiquetados de várias formas, levou também a uma análise mais detalhada, isso foi bom pois deu para perceber desde logo algumas diferenças nos sinais.

O treino do classificador SVM usando a toolbox STPRTool mostrou-se bastante lento, o que levou muito tempo para se poder proceder à análise dos dados que dele resultavam.

A fase dos testes em ambiente real seria a fase no qual se iria verificar se a nossa aplicação estava em correto funcionamento e a deteção acertada dos estados. Devido aos atrasos já referidos, esta fase também se atrasou, sendo que a adesão foi muito pouca, pois o aparelho em si é um pouco incómodo para o utilizador.

Este estágio permitiu reforçar e apreender novos conhecimentos, assim como perceber um pouco do mundo do trabalho e neste caso da investigação. Foi muito bom ter conhecido pessoas de outras áreas e saber que o trabalho colaborativo e multidisciplinar dá frutos.

Trabalho futuro

Futuramente pensa-se avaliar este sistema em ambiente fabril onde o processo de fabrico se caracteriza muitas vezes por uma rotina que causa maior cansaço e potencial para a existência de estados de pré-sono dos quais resultam acidentes de trabalho. Estes sistemas seriam facilmente implementados em capacetes usados pelos trabalhadores e dos quais poderia extrair-se todos os dados necessários.

Pensando em outro tipo de aplicações, poder-se-ia também fazer um estudo com este tipo de tecnologias para a análise de movimentos de cabeça usando os giroscópios do *Emotiv*. Por exemplo, numa exposição seria possível detetar quais os pontos mais focados pelas pessoas e, conseqüentemente, perceber aqueles que lhes despertaram maior interesse. Dos dados extraídos poder-se-ia retirar, também, informação relativa ao tempo que a pessoa leva a reparar num determinado quadro. Num estudo mais aprofundado também poderia ser possível a monitorização das pessoas com doenças relacionadas com o cérebro. Desta forma, seria possível detetar precocemente aquelas doenças e proceder a determinadas ações e minimizar conseqüências. Por outro lado, também poderíamos monitorizar pessoas com problemas de memória ou movimento, permitindo nomeadamente aos seus familiares obter informações acerca do estado e local da pessoa monitorizada.

Referências

- [1] Atlas da saúde; "Resultados do Estudo Europeu sobre Sono ao volante"; <http://www.atlasdasaude.pt>; [acedido em 16/09/2013].
- [2] Polissonografia; <http://pt.wikipedia.org/wiki/Polissonografia>; [acedido em 25/09/2013]
- [3] Ron A Shatzmiller, MD, MSc; "Sleep Stage Scoring".
- [4] Sleep Architecture; "<http://evolutionarypsychiatry.blogspot.pt/2011/01/sleep-architecture.html>"; [acedido em 07/10/2013].
- [5] Togawa, T., Tamura, T., Oberg, P.; "Biomedical transducers and instruments"; CRC Press LLC, 1997.
- [6] J Neurol Neurosurg Psychiatry. 2003 Jan;74(1):9. Hans Berger (1873-1941), Richard Caton (1842-1926), and electroencephalography. Haas LF.
- [7] Jaakko Malmivuo, Robert Plonsey; "Bioelectromagnetism - Principles and Applications of Bioelectric and Biomagnetic Fields"; Oxford University Press, 1995.
- [8] Sharbrough F, Chatrian G-E, Lesser RP, Lüders H, Nuwer M, Picton TW ; " American Electroencephalographic Society Guidelines for Standard Electrode Position Nomenclature"; J. Clin. Neurophysiol 8: 200-2, 1991
- [9] Dr. Jeffrey Ricker's; "An Introduction to the Psychological Sciences"; Section 2.8-Stages of sleep.
- [10] Sleep; <http://en.wikipedia.org/wiki/Sleep>; [acedido em 09/10/2013].
- [11] Barros Vilela; "Fundamentos da Eletromiografia"; <http://www.cpaqv.org/mtpmh/eletromiografia.pdf>; [acedido em 15/10/2013].
- [12] A Bulling, JA Ward, H Gellersen, G Tröster; "Eye Movement Analysis for Activity Recognition Using Electrooculography"; 2010 – IEEE.
- [13] Lilian Ribeiro Mendes Paiva, Adriano Alves Pereira, Adriano de Oliveira Andrade; "Métodos Computacionais e Estatísticos no Estudo das Ondas de Frequência dos Sinais Eletroencefalográficos e o Envelhecimento: uma bordagem Através da Análise Linear do Discriminante"; 2013.
- [14] Peter Achermann; "EEG Analysis Applied to Sleep"; Epileptologie 2009.
- [15] CA Teixeira, B Direito, H Feldwisch-Drentrup, M Valderrama, RP Costa, C Alvarado-Rojas, S Nikolopoulos, M Le Van Quyen, Jens Timmer, B Schelter, AEPILAB Dourado; "EPILAB: A software package for studies on the prediction of epileptic seizures"; 2011/9/15.

- [16] Android, the world's most popular mobile platform; <http://developer.android.com/about/index.html>; [acedido em 28/10/2013].
- [17] USB Host and Accessory; <http://developer.android.com/guide/topics/connectivity/usb/index.html>; [acedido em 28/10/2013].
- [18] Research Edition; "<http://emotiv.com/store/sdk/bci/research-edition-sdk/>"; [acedido em 28/10/2013].
- [19] Cooley J W & Tukey J W;" An algorithm for the machine calculation of complex Fourier series"; Math. Comput. 19:297-301, 1965.
- [20] Hjorth B.;" EEG analysis based on time domain properties. Electroencephalogr Clin Neurophysiol"; 1970;29(3):306–10.
- [21] Cortes, Corinna; and Vapnik, Vladimir N.; "Support-Vector Networks"; Machine Learning, 20, 1995.
- [22] Bernardo Penna Resende de Carvalho; "O estado da arte em métodos para reconhecimento de padrões: Support Vector Machine"; 2005.
- [23] CHRISTOPHER J.C. BURGESS; "A Tutorial on Support Vector Machines for Pattern Recognition"; Bell Laboratories, Lucent Technologies.
- [24] R. Fletcher; "Practical Methods of Optimization"; John Wiley and Sons, Inc., 2nd Edition, 1987.
- [25] Carlos Gershenson; "Artificial Neural Networks for Beginners".
- [26] Sharbrough F, Chatrian G-E, Lesser RP, Lüders H, Nuwer M, Picton ;" American Electroencephalographic Society Guidelines for Standard Electrode Position Nomenclature"; J. Clin. Neurophysiol 8: 200-2.
- [27] B. Yegnanarayana; "Artificial Neural Networks"; PHI Learning Pvt. Ltd"; 14/01/2009.
- [28] Hervé Abdi; "Neural Networks"; The University of Texas at Dallas.
- [29] Artificial Neural Network; http://www.saedsayad.com/artificial_neural_network.htm; [acedido em 04/11/2013].
- [30] David Reby, Sovan Lek, Ioannis Dimopoulos, Jean Joachim, Jacques Lauga, Stéphane Aulagnier; "Artificial neural network as a classification method in the behavioural sciences"; behavioural Processes 40 (1997) 35-45.
- [31] Gallant, Stephen I; "Neural network Learning and expert systems"; MIT Press, 1993.

- [32] Volney Gadelha Lustosa; "O Estado da Arte em Inteligência Artificial"; Fevereiro de 2004.
- [33] Nir Friedman, Dan Geiger, Moises Goldszmidt; "Bayesian Network Classifiers"; Machine Learning, 29, 1997.
- [34] Ben-Gall, Bayesian Network, in Ruggeri F., Faltin F. & Kenett R.; Encyclopedia of statistics in Quality & Reliability; Wiley & Sons (2007).
- [35] X. Wu, V. Kumar, J. Ross Quinlan, J. Ghosh, Q. Yang, H. Motoda; "Top 10 algorithms in data mining"; 4 December 2007, © Springer-Verlag London Limited 2007.
- [36] Ahmad Tauseef Sohaib, Shah Nawaz Qureshi, Johan Hagelbäck, Olle Hilborn, Petar Jerčić; "Evaluating classifiers for Emotion Recognition using EEG"; Volume 8027, 2013, pp 492-501.
- [37] André Tiago Marques Reis; "Sistema de classificação de sinais de electroencefalograma"; Universidade de Aveiro, 2008.
- [38] Leo Kelion; "Caterpillar backs eye-tracker to combat driver fatigue"; 28 May 2013, <http://www.bbc.co.uk/news/technology-22640279> [acedido em 07/01/2014].
- [39] Luis Fernando Nicolas-Alonso, Jaime Gomez-Gil; "Brain Computer Interfaces, a Review"; *Eléctrodos* 2012, 12(2), 1211-1279; doi:10.3390/s120201211, 31 January 2012.
- [40] Josimara de Ávila Silveira; "Análise de Sinais Cerebrais Utilizando Árvores de Decisão"; 24 de maio de 2013.
- [41] Brennan, K.; "Um guia para o Corpo de Conhecimento de Análise de Negócios"; 2 ed. International Institute of Business Analysis, Boston, Massachusetts, 2009.
- [42] Carmen Vidaurre, Nicole Krämer, Benjamin Blankertz, Alois Schlögl; "Time Domain Parameters as a feature for EEG-based Brain-Computer Interfaces"; *Neural Networks* 22 (2009)
- [43] Mormann F, Kreuz T, Rieke C, Andrzejak RG, Kraskov A, David P.; "On the predictability of epileptic seizures. *Clinical Neurophysiology*"; 116:569–87, et al. (2005).
- [44] Iola Maria Silvério Pinto; "Estatística Descritiva e Análise Exploratória de Dados"; Instituto Superior de Engenharia de Lisboa, 2011.
- [45] Society, I. C. IEEE Recommended Practice for Software Requirements Specification. IEEE Std 830-1998 (1998), 1-40.
- [46] Eye Tracking; http://en.wikipedia.org/wiki/Eye_tracking; [acedido em 17/02/2014].
- [47] Heart rate Variability; http://en.wikipedia.org/wiki/Heart_rate_variability; [acedido em 17/02/2013].

- [48] Peixoto, Roger André Oliveira;" Estudo da atividade nervosa autonômica durante o sono através da análise espectral wavelet da variabilidade da frequência cardíaca em sujeitos obesos mórbidos submetidos à cirurgia bariátrica."; São Paulo,2010.
- [49] WANG, X.; "Incorporating Knowledge on Segmental Duration in HMM-Based Continuous Speech Recognition"; 1997.
- [50] F. Jelinek.; "Statistical Methods for Speech Recognition"; The MIT Press, 1998.
- [51] Baum L. E, Petrie T.; "Statistical Inference for Probabilistic Functions of Finite State Markov Chains"; Ann Math. Stat. 37, pp.1554-1563, 1966.
- [52] Baum L. E, Eagon J. A.; "An Inequality with Applications to Statistical Estimation for Probabilistic Functions of a Markov Process and to a Model for Ecology"; Bull. Amer. Math. Soc. 73, pp. 360-363, 1967.
- [53] Baker J. K.; "Stochastic Modeling as a Means of Automatic Speech Recognition"; PhD. Dissertation, Carriegie-Mellon University, 1975
- [54] Oliveira, Luiz Eduardo Soares;Morita, Marisa Emika; "Introdução aos Modelos Escondidos de Markov (HMM)".
- [55] Redes bayseanas; "http://www.lx.it.pt/~afred/docencia/Percepcao_2006/acetatos/rb.pdf."; [acedido em 04/08/2014].
- [56] Accelerometer; <http://en.wikipedia.org/wiki/Accelerometer>; [acedido em 12/03/2013]
- [57] Driver State Eléctrodo; <http://www.seeingmachines.com/product/dss/fatigue-in-transportation/>; [acedido em 12/03/2013]
- [58] Alex Poole, Linden J.Ball; "Eye Tracking in Human-Computer Interaction and Usability Research: Current Status and Future Prospects"; Psychology Department, Lancaster University, UK
- [59] Goldberg, H. J., & Wichansky, A. M.; " Eye tracking in usability evaluation: A practitioner's guide"; (2003)
- [60] Redline, C. D., & Lankford; Eye-movement analysis: A new tool for evaluating the design of visually administered instruments (paper and web). In Proceedings of the Section on Survey Research Methods of the American Statistical Association. C. P. (2001).
- [61] Li, G. and Chung, WY. ;"Detection of Driver Drowsiness Using Wavelet Analysis of Heart Rate Variability and a Support Vector Machine Classifier."; *Eléctrodo* (2013) 13(12), 16494-16511.
- [62] Chunlin Zhao, Chongxun Zheng, Min Zhao, Jianping Liu2; " Physiological Assessment of Driving Mental Fatigue Using Wavelet Packet Energy and Random Forests "; Institute of

Biomedical Engineering of Xi'an Jiaotong University No.28. Xianning West Road. Xi'an, Shanxi, 710049. P.R. China.

[63] Jui-Lien Chen, Ding-Peng Yeh, Jo-Ping Lee, Chung-Yu Chen, Chih-Yang Huang, Shin-Da Lee, Chiu-Chou Chen, Terry B.J. Kuo, Chung-Lan Kao, Chia-Hua Kuo; "Parasympathetic nervous activity mirrors recovery status in weightlifting performance after training"; Journal of Strength and Conditioning Research; 2011 National Strength and Conditioning Association.

[64] Heart Rate Variability Research Review; <http://www.8weeksout.com/2011/12/05/heart-rate-variability-research-review/>; [acedido em 03/05/2014]

[65] Toyota works on steering wheel with built-in ECG; http://smehorizon.sulekha.com/toyota-works-on-steering-wheel-with-built-in-ecg_automotive-viewsitem_4088; [acedido em 03/05/2014]

[66] Alan L owne;"Non-contact ECG measurement using EPIC Eléctrodos";

[67] Tom Fawcett;"An introduction to ROC analysis";Institute for the Study of Learning and Expertise, 2164 Staunton Court, Palo Alto, CA 94306, USA.

[68] Bernardete Ribeiro ;Acetatos da cadeira de Técnicas de Reconhecimento de padrões; DEI-FCTUC, Faculdade de Coimbra.

[69] Alex Brandão Rossow; "CLASSIFICAÇÃO DE ESTÁGIOS DO SONO PELA ANÁLISE DO SINAL DE EEG";

[70] The Area Under an ROC Curve; <http://gim.unmc.edu/dxtests/roc3.htm> [acedido em 18/06/2014].

[71] The Sleep-EDF Database; <http://www.physionet.org/physiobank/database/sleep-edfx/> [acedido em 03/03/2014].

[72] Rosário cação; "Testes estatísticos testes paramétricos e testes não paramétricos" <http://pt.slideshare.net/rosariocacao/testes-parametricos-e-nao-parametricos-3396639> [acedido em 20/07/2014].

[73] McDonald; "Handbook of Biological Statistics."; J.H. 2009; Sparky House Publishing, Baltimore, Maryland.

[74] Kruskal-wallis one-way analysis of variance;" http://en.wikipedia.org/wiki/Kruskal%E2%80%93Wallis_one-way_analysis_of_variance"; [acedido em 04/08/2014].

[75] John G.Proakis, Dimitris G. Manolakis; "Digital Signal Processing, principles, algorithms, and applications"; third edition

[76] Hugo Simões, Gabriel Pires, Urbano Nunes, Vitor Silva; "Feature Extraction and Selection for Automatic Sleep Staging using EEG. "; ICINCO (3), 2010.

[77] Steinn Gudmundsson, Thomas Philip Runarsson, Sven Sigurdsson; "Automatic Sleep Staging using Support Vector Machines with Posterior Probability Estimates"

[78] Statistical Pattern Recognition Toolbox; "<http://cmp.felk.cvut.cz/cmp/software/stprtool/>"; [acedido em 04/08/2014].

[79] Receiver operating characteristic; http://en.wikipedia.org/wiki/Receiver_operating_characteristic"; [acedido em 04/08/2014].

Anexos

Anexo A

Análise de Riscos

Existem sempre vários riscos associados a cada desenvolvimento e implantação de um novo software, riscos esses que nem sempre são derivados da equipa ou dos meios, podem ser também riscos externos que vão influenciar no desenvolvimento do projecto. De seguida são detalhados os riscos que se foram detectando ao longo de desenvolvimento e a forma como foram mitigados.

Risco N°: 01	Impacto: Critico	Prioridade: Alta
Título	Dispositivo móvel não estar disponível	
Descrição	Não temos um dispositivo com capacidade para uma interligação com o <i>hardware</i> disponível. Pois o que foi disponibilizado não tem capacidade de interligação com dispositivos <i>Human Interface Device</i>	
Identificação	17 Setembro 2013	
Estado:	Foi disponibilizado um novo dispositivo com as capacidades necessárias para se proceder ao desenvolvimento da aplicação.	

Risco N°: 02	Impacto: Critico	Prioridade: Alta
Título	Aquisição de dados de doentes	
Descrição	Para se proceder a análise e elaboração de um classificador capaz de detectar precocemente o estado de sonolência será necessário sinais EEG de pacientes.	
Identificação	17 Dezembro 2013	
Estado:	Já está em pratica um plano de recolha de dados de pacientes dos Hospitais da universidade de Coimbra, de forma a que os dados estejam disponíveis para análise.	

Risco Nº: 03	Impacto: Médio	Prioridade: Média
Título	Poucos utilizadores para efectuar testes da aplicação	
Descrição	Para se conseguir verificar se a aplicação esta a detectar correctamente os estados de sonolência é necessário efectuar análise em vários indivíduos.	
Identificação	17 Dezembro 2013	
Estado:	Vamos recrutar pessoas próximas para poderem efectuar esses testes.	

Risco Nº: 04	Impacto: Crítico	Prioridade: Alta
Título	Classificação dos dados após análise dos estados	
Descrição	A quando dos testes efectuados aos indivíduos é necessário que um especialista na área verifique que se os pontos onde a nossa aplicação disse que ocorreu um estado de sonolência, estão identificados correctamente	
Identificação	17 Dezembro 2013	
Estado:	Indefinido	

Risco Nº: 05	Impacto: Crítico	Prioridade: Média
Título	Disponibilidade do Técnico do Hospital da Universidade de Coimbra	
Descrição	É necessário que um especialista na área da sonolência verifique os dados recolhidos pelo nosso dispositivo.	
Identificação	17 Dezembro 2013	
Estado:	Não será possível ter uma certeza se serão caracterizados ainda durante o corrente tempo de estágio.	

Anexo B

Testes a aplicação

Teste N ^o : 01	
Título	Acesso a aplicação
Descrição	A permissão de dispositivos móveis tem que ser requerida sempre que um novo dispositivo se conecte a cada ligação de aplicação
Estado:	Feito

Teste N ^o : 02	
Título	Leitura de dados
Descrição	Verificar se são apresentados em todos os gráficos e a respectiva informação
Estado:	Feito

Teste N ^o : 03	
Título	Qualidade do sinal
Descrição	Verificar se todos os eléctrodos alteram de cor
Estado:	Feito

Teste N ^o : 04	
Título	Qualidade de bateria
Descrição	Verificar o valor da bateria é alterado
Estado:	Feito

Teste N ^o : 05	
---------------------------	--

Título	Seleccionar eléctrodo
Descrição	Alterar o eléctrodo analisar
Estado:	Feito

Teste N°: 06	
Título	Alterar a percentagem
Descrição	Verificar se a percentagem nas características de frequência espectral é alterada
Estado:	Não realizado

Teste N°: 07	
Título	Verificar se alarme funciona
Descrição	Fazer um teste de alarme e verificar se o mesmo funciona
Estado:	Feito

Teste N°: 08	
Título	Sair e voltar a entrar na aplicação
Descrição	Com este teste é possível verificar se a aplicação continua em correcto funcionamento.
Estado:	Feito, por vezes volta a pedir permissão, sendo que tem que se fechar.

Teste N°: 09	
Título	Fechar a aplicação
Descrição	Verificar se quando a aplicação é encerrada, se a mesma efectua todo o processo de encerramento
Estado:	Feito, por vezes não encerra por completo.

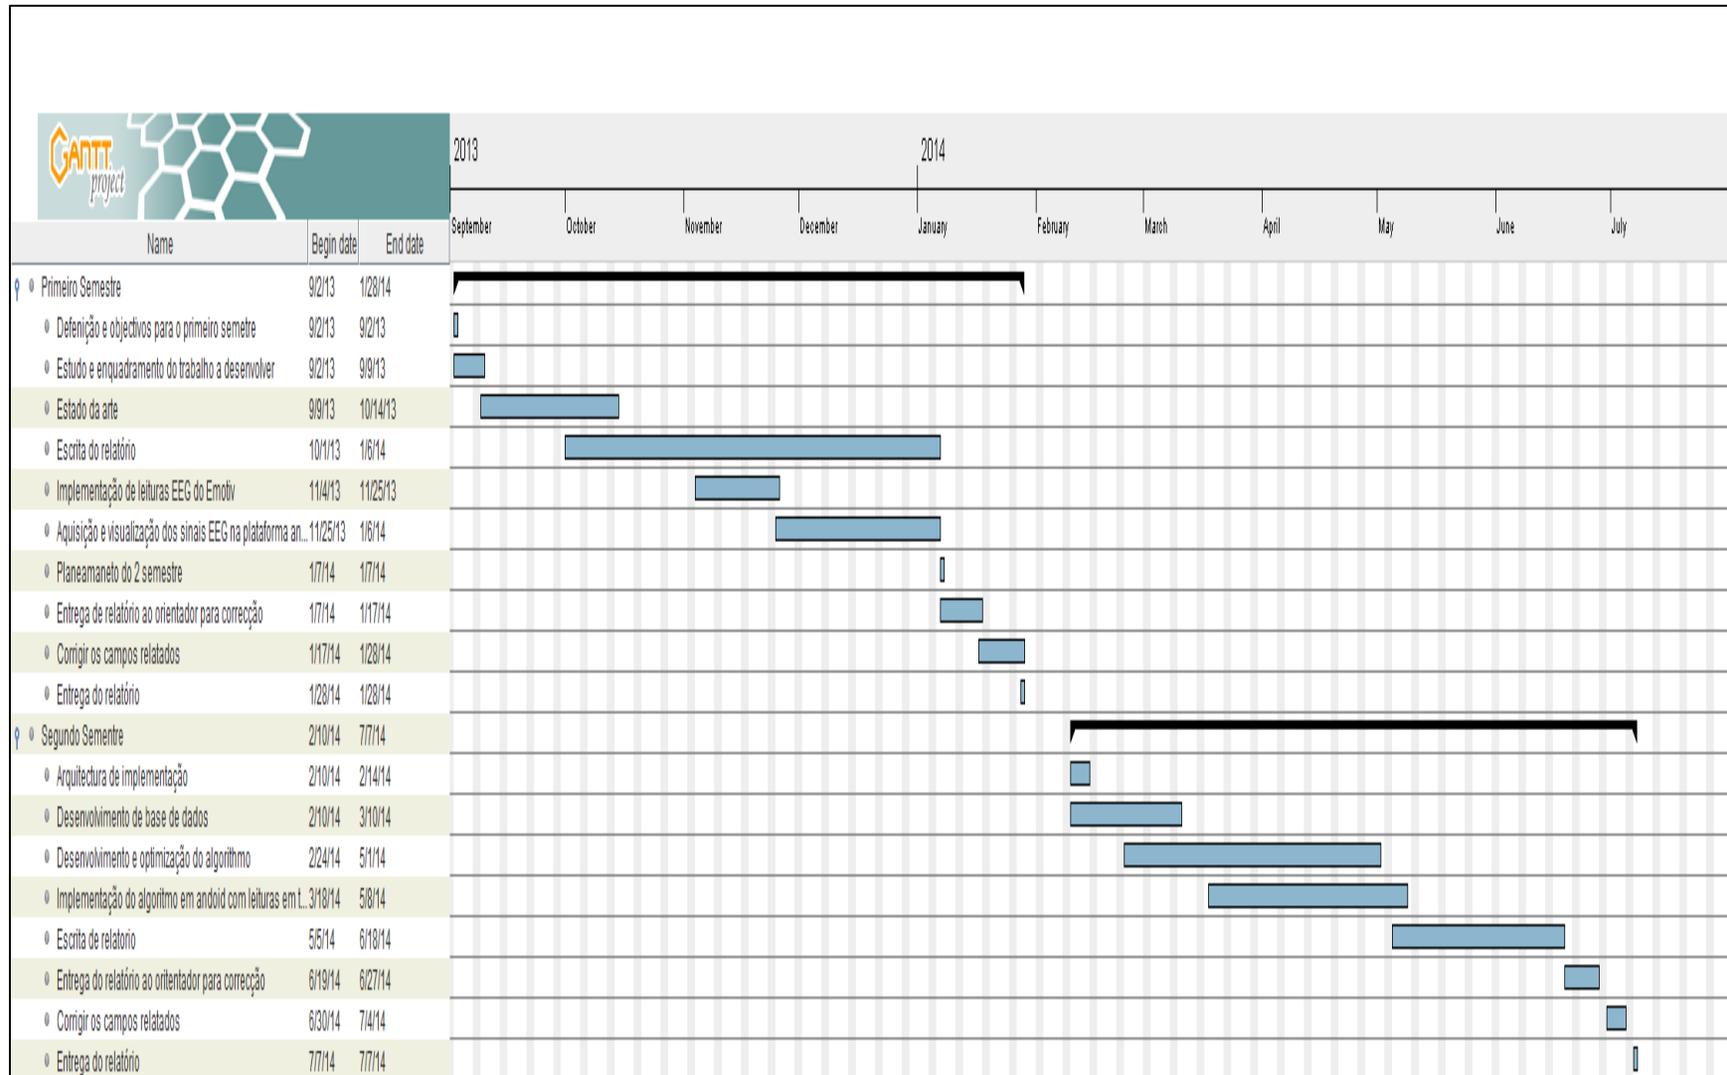
Anexo C

Cronograma

Inicialmente tivemos as seguintes ordens de trabalho sendo que as mesmas foram actualizadas:

Nome	Data Início	Data Fim
Definição e objectivo para o primeiro semestre	2 Setembro 2013	2 Setembro 2013
Estudo e enquadramento do trabalho a desenvolver	2 Setembro 2013	9 Setembro 2013
Estado da arte	9 Setembro 2013	14 Outubro 2013
Escrita do relatório	1 Outubro 2013	6 Janeiro 2014
Implementação de Leituras EEG do Emotiv	4 Novembro 2013	25 Novembro 2013
Aquisição e visualização dos sinais EEG na plataforma Android	25 Novembro 2013	6 Janeiro 2014
Planeamento do 2º Semestre	7 Janeiro 2014	7 Janeiro 2014
Entrega de relatório ao orientador para correcção	7 Janeiro 2014	17 Janeiro 2014
Corrigir os campos relatados	17 Janeiro 2014	28 Janeiro 2014
Entrega do relatório	28 Janeiro 2014	28 Janeiro 2014
Arquitectura de implementação	10 Fevereiro 2014	14 Fevereiro 2014
Desenvolvimento de base de dados	10 Fevereiro 2014	10 Março 2014
Desenvolvimento e optimização de algoritmo	24 Fevereiro 2014	1 Maio 2014
Implementação do algoritmo em Android	18 Março 2014	8 Maio 2014
Escrita de relatório	5 Maio 2014	18 Junho 2014
Entrega do relatório ao orientador para correcção	19 Junho 2014	27 Junho 2014
Corrigir campos relatados	30 Junho 2014	7 Julho 2014
Entrega do relatório	7 Julho 2014	7 Julho 2014

Cronograma inicialmente programado:

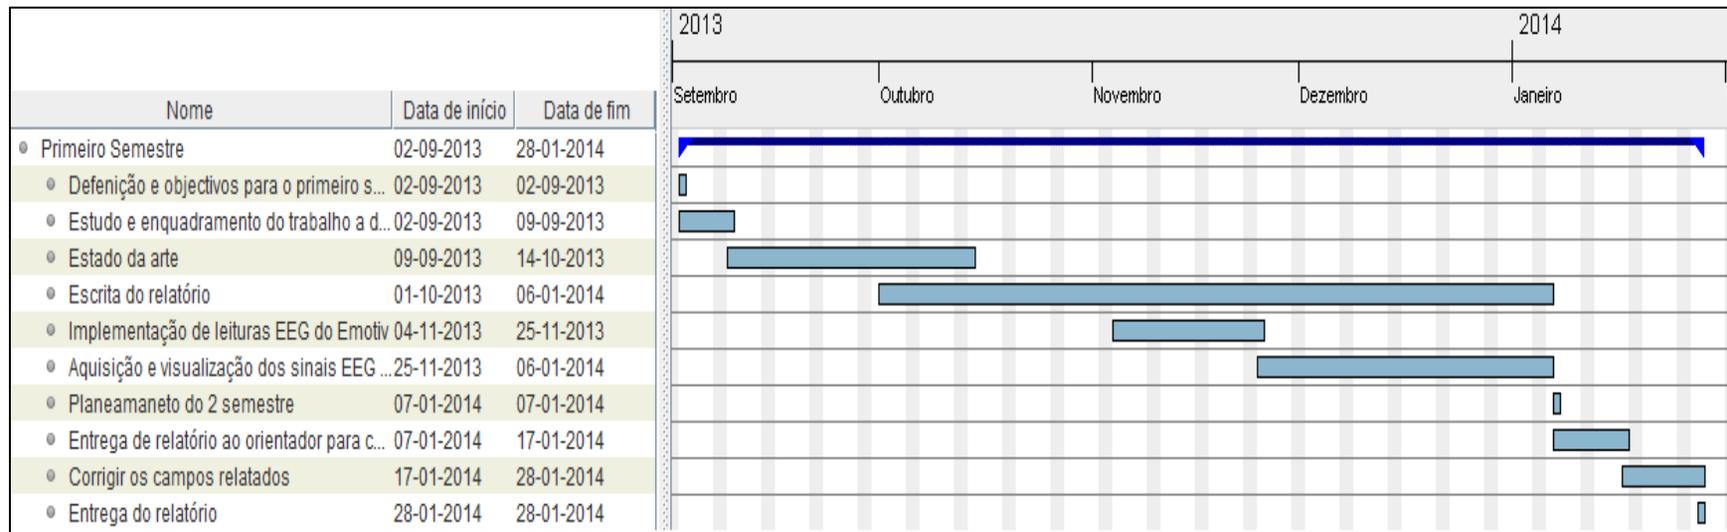


Primeiro Semestre:

Tarefa	Data Início	Data Fim
Início Projecto	1 Setembro 2013	1 Setembro 2013
Definição e objectivo para o primeiro semestre	2 Setembro 2013	2 Setembro 2013
Estudo e enquadramento do trabalho a desenvolver	2 Setembro 2013	9 Setembro 2013
Estado da arte	9 Setembro 2013	14 Outubro 2013
Escrita do relatório	1 Outubro 2013	6 Janeiro 2014
Implementação de Leituras EEG do <i>Emotiv</i>	4 Novembro 2013	25 Novembro 2013
Aquisição e visualização dos sinais EEG na plataforma Android	25 Novembro 2013	6 Janeiro 2014
Planeamento do 2º Semestre	7 Janeiro 2014	7 Janeiro 2014
Entrega de relatório ao orientador para correcção	7 Janeiro 2014	17 Janeiro 2014
Corrigir os campos relatados	17 Janeiro 2014	28 Janeiro 2014
Entrega do relatório	28 Janeiro 2014	28 Janeiro 2014

Relativamente ao primeiro semestre todo o cronograma foi cumprido sem que houvesse qualquer problema com o projecto.

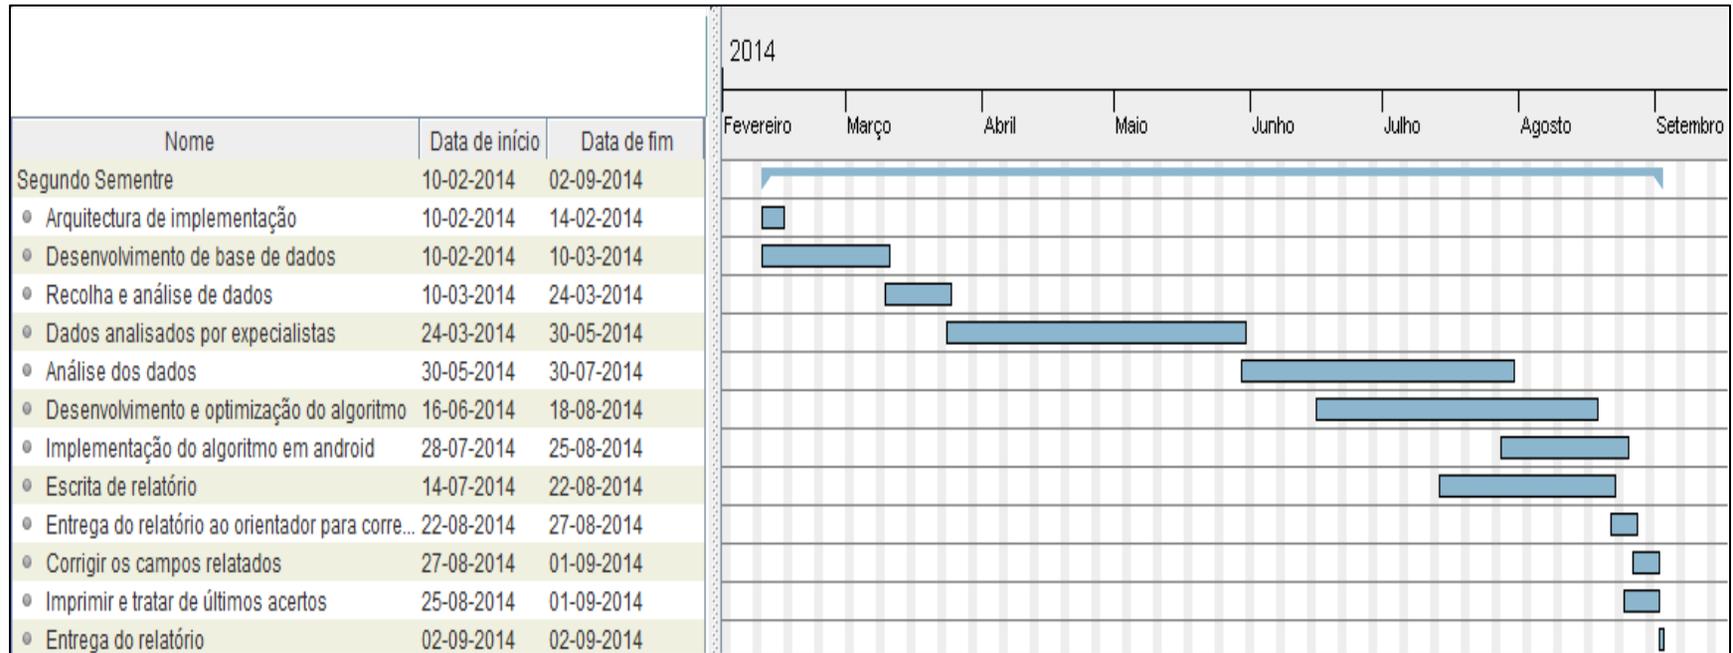
Primeiro Semestre



Segundo Semestre:

Tarefa	Data Início	Data Fim
Arquitectura de implementação	10 Fevereiro 2014	14 Fevereiro 2014
Desenvolvimento de base de dados	10 Fevereiro 2014	10 Março 2014
Recolha e análise de dados	10 Março 2014	24 Março 2014
Dados analisados por especialistas	24 Março 2014	30 Maio 2014
Análise dos dados	30 Maio 2014	30 Julho 2014
Desenvolvimento e optimização do algoritmo	16 Junho 2014	18 Agosto 2014
Implementação do algoritmo em android	28 Julho 2014	25 Agosto 2014
Escrita de relatório	14 Julho 2014	22 Agosto 2014
Entrega do relatório ao orientador para correcção	22 Agosto 2014	27 Agosto 2014
Corrigir os campos relatados	27 Agosto 2014	1 Setembro 2014
Imprimir e tratar de últimos acertos	25 Agosto 2014	1 Setembro 2014
Entrega do relatório	2 Setembro 2014	2 Setembro 2014

Segundo Semestre



Cronograma final:

