



UNIVERSIDADE DA BEIRA INTERIOR  
Engenharia

# **Classification Models for Sleep Apnea Detection**

(versão final após defesa)

**André Miguel da Silva Pinho**

Dissertação para obtenção do Grau de Mestre em  
**Engenharia Informática**  
(2º ciclo de estudos)

Orientador: Prof. Doutor Nuno Pombo  
Co-orientador: Prof. Doutor Nuno Garcia e Prof. Doutor Kouamana Bousson

**Covilhã, Maio de 2019**

## **Classification Models for Sleep Apnea Detection and/or Prediction**

## **Dedicatória**

"I will not follow where the path may lead, but I will go where there is no path, and I will leave a trail."

Muriel Strode, from *Wind-Wafted Wild Flowers*

Dedicado às várias pessoas que decidiram deixar um trilho ao invés de perseguirem um caminho comum a tantas outras. Obrigado - pela vossa coragem e exemplo. - AP

## **Classification Models for Sleep Apnea Detection and/or Prediction**

## **Agradecimentos**

A todos os que directa ou indirectamente contribuíram na realização deste estudo e na minha conclusão de mais uma etapa, um muito obrigado.

## **Classification Models for Sleep Apnea Detection and/or Prediction**

## **Resumo**

A dissertação incide na selecção de características, importância das mesmas num modelo de classificação e diferentes tipos de classificação para uma melhor detecção de apneia de sono, recorrendo apenas a um electrocardiograma (ECG) e comparando a precisão dos diferentes modelos. Recorrendo ao uso da base de dados Physionet Apnea-ECG, um filtro Savitsky Golay (sgolay) foi aplicado aos registos para limpar o sinal e depois obter o complexo QRS de forma a obter o Heart Rate Variability (HRV) e o ECG-Derived Respiration (EDR). As características extraídas destes dois métodos foram usadas para treino, teste e validação dos classificadores. As características obtidas foram analisadas por forma a se seleccionar as mais relevantes no contexto da detecção de apneia. Os conjuntos de treino e teste foram obtidos dividindo aleatoriamente os dados até uma boa performance ser atingida usando o k-fold cross-validation (k=10). De acordo com os resultados obtidos, a melhor precisão foi de 82.12%, com uma sensibilidade e uma especificidade de 88.41% e 72.29%, respectivamente. Estes resultados preliminares podem levar a estudos complementares para implementação numa aplicação real.

## **Palavras-chave**

Apneia de Sono, Electrocardiograma (ECG), Heart Rate Variability (HRV), ECG-Derived Respiration (EDR), Selecção de características, Classificadores, Rede Neuronal, Support Vector Machine (SVM), Linear Discriminant Analysis (LDA), Partial Least Squares Regression (PLS), Regression Analysis (REG), Wiener-Hopf equation (WienerHopf), Augmented Naive Bayesian Classifier (aNBC), Perceptron Learning Algorithm (PLA), Least mean squares (LMS)



# Índice

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Enquadramento . . . . .	1
1.2	Organização do Documento . . . . .	2
<b>2</b>	<b>Apneia do Sono</b>	<b>3</b>
2.1	Visão Geral . . . . .	3
2.2	Tipos de apneia . . . . .	4
2.3	Epidemiologia . . . . .	4
2.4	Efeitos da apneia do sono . . . . .	4
2.5	Sintomas . . . . .	4
2.5.1	Sintomas Adultos . . . . .	5
2.5.2	Efeitos Cardiovasculares da Apneia de Sono . . . . .	5
2.6	Diagnóstico . . . . .	5
2.6.1	Polissonografia . . . . .	6
<b>3</b>	<b>Estado da Arte</b>	<b>7</b>
3.1	Introdução . . . . .	7
3.2	Combinação de Classificadores . . . . .	8
3.3	Seleção das Características . . . . .	8
3.4	Detecção de Apneia Usando Adaptive Neuro Fuzzy Inference System . . . . .	9
3.5	Detecção de Apneia em Tempo Real . . . . .	10
3.6	Recorrer ao CMORWT-Based Feature of Time-Frequency Area . . . . .	10
3.7	Detectar Apneia do Sono com Linear Discriminant e Quadratic Discriminant . . . . .	11
3.8	Rede neuronal para detectar Apneia do Sono . . . . .	13
3.9	Detecção de apneia do sono usando Least-squares Support Vector Machine . . . . .	13
3.10	Detecção de Apneia de Sono usando Extreme Learning Machine . . . . .	14
3.11	Detecção de Artefactos para Detecção de Apneia de Sono . . . . .	14
3.12	Técnicas de Classificação . . . . .	15
3.12.1	Redes Neurais . . . . .	15
3.12.2	Support Vector Machines (SVM) . . . . .	16
3.12.3	Linear Discriminant Analysis (LDA) . . . . .	16
3.12.4	Partial Least Squares Regression (PLS) . . . . .	17
3.12.5	Regression analysis (REG) . . . . .	17
3.12.6	Wiener-Hopf . . . . .	17
3.12.7	Augmented Naive Bayesian Classifier (aNBC) . . . . .	17
3.12.8	Perceptron Learning Algorithm (PLA) . . . . .	17
3.12.9	Least mean squares (LMS) . . . . .	18
3.13	ECG e Apneia de Sono . . . . .	18
3.13.1	ECG . . . . .	18
3.13.2	Apneia do Sono através do ECG . . . . .	19
3.14	Conclusões . . . . .	20

<b>4</b>	<b>Tecnologias e Ferramentas Utilizadas</b>	<b>21</b>
4.1	Introdução . . . . .	21
4.2	Linguagem de Programação . . . . .	21
4.2.1	Funções e Pacotes Usados . . . . .	21
4.3	Dados usados para Análise . . . . .	22
4.4	Conclusões . . . . .	22
<b>5</b>	<b>Implementação e Testes</b>	<b>23</b>
5.1	Introdução . . . . .	23
5.2	Leitura da Base de Dados . . . . .	23
5.3	Detecção do complexo de QRS . . . . .	23
5.4	Extração das características . . . . .	25
5.5	Seleccção de características . . . . .	27
5.6	Classificação . . . . .	28
5.6.1	Rede Neuronal . . . . .	29
5.6.2	Support Vector Machine (SVM) . . . . .	29
5.7	Resultados . . . . .	29
5.8	Discussão . . . . .	33
5.9	Conclusão . . . . .	34
<b>6</b>	<b>Conclusões e Trabalho Futuro</b>	<b>35</b>
6.1	Conclusões Principais . . . . .	35
6.2	Trabalho futuro . . . . .	35
	<b>Bibliografia</b>	<b>37</b>

## Lista de Figuras

2.1	Exemplo de um exame de polissonografia. . . . .	5
3.1	Arquitetura ANFIS . . . . .	10
3.2	Representação do complexo QRS e do sinal ECG. . . . .	18
3.3	Exemplo de um momento normal num sinal ECG com a duração de um minuto. . . . .	19
3.4	Exemplo de um momento de apneia do sono num sinal ECG com a duração de um minuto. . . . .	19
5.1	A standard multi-layer ANN structure with l layers of units . . . . .	29
5.2	Comparação dos resultados da sensibilidade. . . . .	30
5.3	Comparação dos resultados da especificidade. . . . .	30
5.4	Comparação dos resultados da precisão. . . . .	33



## Lista de Tabelas

3.1	Artefact Detection Algorithm . . . . .	15
5.1	Time-Domain Measure For HRV(m) Epoch Sequence . . . . .	26
5.2	Time-Domain Measure For EDR(q) Epoch Sequence . . . . .	26
5.3	Spectral-Domain measures for HRV and EDR epoch sequences . . . . .	27
5.4	Resultados para os diferentes conjuntos de características com comparação entre classifica- dores. . . . .	31
5.5	Resultados para os diferentes conjuntos de características com comparação entre classifica- dores . . . . .	32

## Classification Models for Sleep Apnea Detection and/or Prediction

## Lista de Acrónimos

ACF	Autocorrelation Function
aNBC	Augmented Naive Bayesian Classifier
ANFIS	Adaptive Neuro Fuzzy Inference System
AVC	Acidente Vascular Cerebral
CSA	Central Sleep Apnea
ECG	Electrocardiograma
EDR	ECG-Derived Respiration
ELM	Extreme Learning Machine
HRV	Heart Rate Variability
Hz	Hertz
kNN	k-Nearest Neighbours
kPCA	kernel Principal Component Analysis
LDA	Linear Discriminant Analysis
LMS	Least Mean Squares
LS-SVM	Least-squares Support Vector Machine
MATLAB	MATrix LABoratory
ms	milisegundos
QD	Quadratic Discriminant
OSA	Obstructive Sleep Apnea
PCA	Principal Component Analysis
PLA	Perceptron Learning Algorithm
PLS	Partial Least Squares Regression
PSG	Polissonografia
PSD	Power Spectral Density
REG	Regression Analysis
RERA	Respiratory Effort-Related Arousal
ROC	Característica de Operação do Receptor
SVM	Support Vector Machines
TANSIG	Tangent Sigmoid
ULWT	Undecimated Lifting Wavelet Transform
WTMM	Wavelet Transformation Modulus Maxima



# Capítulo 1

## Introdução

### 1.1 Enquadramento

A apneia de sono é uma doença do sono comum que é caracterizada por episódios recorrentes de obstruções parciais ou completas da via respiratória, resultando numa fragmentação do sono e dessaturação de oxigénio [OPH<sup>+</sup>16]. A apneia pode dividir-se em três categorias: Obstructive Sleep Apnea (OSA), Central Sleep Apnea (CSA) ou mista. A OSA é caracterizada por interrupção da respiração por bloqueio físico do fluxo de ar, apesar do esforço respiratório, levando ao ressonar do paciente. A CSA é caracterizada por falta de esforço respiratório. A apneia mista consiste numa combinação destas duas apneias referidas anteriormente. A apneia do sono contribui para o aumento da morbilidade e problemas cardiovasculares [KGH<sup>+</sup>14]. Como problemas cardiovasculares são a principal causa de mortalidade [OLA<sup>+</sup>16], a falta de tratamento à apneia de sono é um encargo significativo para a saúde pública e um grande desafio em termos de previsão, detecção e/ou tratamento. Um diagnóstico de apneia de sono é feito através da contagem do número de eventos de apneia num período de tempo (uma noite de sono). A contagem média por hora dos eventos de apneia é uma métrica relevante nos padrões comumente usados, como o índice de apneia/hipoapneia (IAH) [RRO<sup>+</sup>09a] ou o índice de distúrbio respiratório (RDI) [RRO<sup>+</sup>09b].

Recentemente, novas abordagens para simplificar a detecção da apneia de sono foram desenvolvidas, baseadas na análise da redução do número de sinais, tais como o Electrocardiograma (ECG) [PVT07, AaKKP08], Electroencefalograma (EEG) [SKN09, HS11], Electromiograma (EMG) [SS15], Oxímetro de Pulso (SpO<sub>2</sub>) [AEFA13] e/ou a combinação de alguns destes mesmos sinais [PG16].

A lógica por trás destas abordagens simplificadas está na tentativa de produzir um método alternativo para a polissonografia (PSG), o método padrão no estudo da apneia do sono, que requer um teste exaustivo num ambiente hospitalar e é de alto custo e desconfortável para o paciente. Assim, o desenvolvimento de técnicas novas, não invasivas e precisas baseadas num conjunto reduzido e simplificado de sinais biométricos [PGB17] pode representar um método alternativo viável e preciso ao PSG. De facto, este cenário permite um registo acessível de dados de pacientes no conforto das suas casas, oferecendo a oportunidade de uma monitorização mais ampla e eficaz da população. Além disso, como a detecção e/ou diagnóstico da apneia de sono é baseada num conjunto reduzido de sinais, as técnicas de processamento de sinais, como filtragem, envolvimento, extração de características e selecção de características tornaram-se críticas para o desempenho dos sistemas computacionais, o que levanta vários desafios. Por um lado, a selecção sábia das características mais informativas e/ou representativas pode levar a melhorar a precisão geral do sistema. Por outro lado, os métodos de selecção de características são propensos a produzir novas características sugeridas que, por sua vez, exigem uma avaliação adicional que pode levar a um aumento dos custos computacionais.

Resumindo, este estudo concentrou-se na avaliação das diferentes características do diagnóstico da apneia de sono com base no sinal de ECG para compreender a importância destas no contexto. Além disso, a comparação de diferentes algoritmos para classificação também foram comparados para compreender a importância da escolha do classificador no contexto. O método proposto poderia fornecer aos profissionais uma ferramenta de diagnóstico robusta, simples e económica em comparação com os esquemas de detecção fornecidos pelo PSG.

Esta dissertação originou a escrita de dois papers produzidos para revista. Os papers são intitulados Towards

an Accurate Sleep Apnea Detection Based on ECG Signal: The Quintessential of a Wise Feature Selection e Classifier Precision Analysis for Sleep Apnea Detection with ECG Signals.

## 1.2 Organização do Documento

Esta dissertação encontra-se organizada da seguinte forma:

1. O primeiro capítulo – **Introdução** – apresenta o estudo com uma breve introdução do problema a tratar e dos objectivos a alcançar com este estudo.
2. O segundo capítulo – **Apneia de Sono** – apresenta o enquadramento mais aprofundado do tema a tratar e contextualiza o leitor para a doença em causa neste estudo.
3. O terceiro capítulo – **Estado da Arte** – apresenta vários estudos que já foram realizados no contexto do problema, assim como as suas falhas e pontos fortes.
4. O quarto capítulo – **Tecnologias e Ferramentas Utilizadas** – apresenta uma descrição breve das ferramentas e tecnologias usadas neste estudo, desde a base de dados até à linguagem de programação usada e seus componentes.
5. O quinto capítulo – **Implementação e testes** – apresenta toda a implementação do sistema e os resultados obtidos.
6. O sexto capítulo – **Conclusões e Trabalho Futuro** – apresenta as conclusões que se podem retirar deste estudo e o trabalho complementar que irá ser feito no futuro de forma a expandir o trabalho realizado.

## Capítulo 2

### Apneia do Sono

Neste capítulo, faz-se uma introdução sobre o problema da doença Apneia de Sono, olhando para os diferentes tipos de apneia, as características, fatores de risco, sintomas e diagnóstico. Além disso, é apresentada a teoria que suporta esta dissertação.

Este capítulo contém as seguintes secções:

- secção 2.1 – **Visão Geral** – apresenta conceitos gerais sobre a doença em estudo.
- secção 2.2 – **Tipos de apneia** – Descreve os diferentes tipos de apneia que existem.
- secção 2.3 – **Epidemiologia** – Apresenta um estudo sobre a população afetada.
- secção 2.4 – **Efeitos da apneia do sono** – Os efeitos na vida dos pacientes com esta doença.
- secção 2.5 – **Sintomas** – Descrição geral de quais são os sintomas.
- secção 2.6 – **Diagnóstico** – Como é realizado o diagnóstico.

#### 2.1 Visão Geral

A apneia de sono é caracterizada pela ocorrência de episódios repetidos de um quadro decorrente da obstrução das vias aéreas superiores (parcial ou totalmente), com diminuição da ventilação durante o sono. Esta situação provoca microdespertares e dessaturação (diminuição da saturação de oxigénio) durante este período.

A uma obstrução parcial da via aérea superior dá-se o nome de hipoapneia e a uma obstrução completa denomina-se apneia (pelo menos 10 segundos). Algumas apneias chegam a demorar vários minutos.

Esta obstrução, na maior parte dos casos, é causada pelo colapso dos tecidos moles na parte de trás da garganta (vias aéreas superiores) e da língua durante o sono, pois os músculos das vias aéreas superiores relaxam quando uma pessoa adormece. Se adormecer em decúbito dorsal, ou de "barriga para cima", propicia esta situação, pois a gravidade vai favorecer o fenómeno da língua cair para trás.

Quando a respiração é suspensa ou o seu ritmo é diminuído, o dióxido de carbono vai-se acumular na corrente sanguínea, pois não é eliminado completamente por esta frequência respiratória baixa. Os quimiorreceptores no organismo vão detetar estes níveis elevados e o cérebro interpreta estes sinais e acorda a pessoa, para que com a recuperação da consciência e, por exemplo, da força muscular na via aérea superior, conseguir finalmente respirar. Assim, irá restaurar os níveis de oxigénio, eliminar o excesso de dióxido de carbono, e a pessoa pode voltar a (pelo menos tentar) adormecer. Este ciclo de eventos pode acontecer várias vezes por noite.

Deve-se ter em atenção que todas as pessoas têm pequenos períodos de apneia durante o sono, o que é normal e fisiológico. No entanto, esses períodos não condicionam nenhum sintoma ou alteração da qualidade do sono.

## 2.2 Tipos de apneia

Há três tipos de Apneia:

- Central
- Obstrutiva mais frequente
- Mista

Na apneia de sono do tipo central, a respiração é interrompida pela "ausência ou diminuição do esforço respiratório".

Na apneia do sono do tipo obstrutivo, a respiração é interrompida por um bloqueio físico ao fluxo aéreo "apesar de esforço respiratório".

Só se considera Síndrome de Apneia Obstrutiva do Sono quando existe repercussão clínica associada às alterações na mecânica ventilatória noturna.

Define-se como a presença de pelo menos 15 eventos respiratórios obstrutivos (sejam apneias, hipoapneias ou Respiratory Effort-Related Arousal (RERA)) por hora de sono, ou pelo menos 5 eventos por hora, se associados à presença de sintomas típicos.

Na apneia do sono complexa (ou mista), há uma transição de características centrais para obstrutivas durante os eventos.

## 2.3 Epidemiologia

Os dados publicados pelas entidades governamentais dos Estados Unidos da América referem que existem 12 milhões de norte-americanos com apneia obstrutiva do sono. Em Portugal, estima-se que atinja cerca de 5% dos portugueses (e 20% dos adultos).

Tem uma incidência maior nos homens - 4% vs 2% no género feminino. Nas mulheres ocorre mais após a menopausa. Independentemente, qualquer pessoa pode ser afetada por apneia de sono.

Independentemente do tipo, um indivíduo com apnéia do sono raramente está consciente de que tem dificuldade em respirar durante a noite. Por isso, estima-se que o número de doentes seja maior do que o que é conhecido. É por isso importante que se aumente o conhecimento sobre a doença e o acesso aos cuidados de saúde especializados na área, nomeadamente ao nível de acesso mais precoce aos exames complementares necessários.

## 2.4 Efeitos da apneia do sono

De uma forma geral, um decréscimo na qualidade de horas de sono pode provocar vários efeitos nefastos. A apneia do sono está associada a pressão arterial elevada (hipertensão), doenças cardíacas, acidente vascular cerebral ou morte precoce, entre outros. Em crianças, pode levar a problemas no crescimento.

## 2.5 Sintomas

Surpreendentemente, apesar das dezenas ou mesmo centenas de despertares por noite, a maioria das pessoas com apneia do sono não tem nenhuma lembrança desses eventos. Na verdade, muitas vezes a única evidência desta condição grave pode ser a fadiga ou a sonolência durante o dia e os relatos dos familiares. No entanto, sabemos que esta perturbação do sono pode resultar numa percepção de sono de má qualidade, apesar dos longos períodos de tempo gastos na cama.

## Classification Models for Sleep Apnea Detection and/or Prediction

### 2.5.1 Sintomas Adultos

Alguns dos sintomas que aparecem em Adultos serão descritos de forma breve nesta subsecção. Além destes também poderemos incluir a disfunção erétil, dor de garganta, fadiga, insónia e o sono não reparador.

#### 2.5.1.1 Sonolência Excessiva Diurna

Trata-se do risco de adormecer durante o dia ao executar atividades rotineiras, como leitura, assistir TV, sentado, deitado, ou a conduzir. Geralmente, estes breves episódios de sono não aliviam a sensação de sonolência.

#### 2.5.1.2 Irritabilidade e deficiente funcionamento mental ou emocional

Estes tipos de sintomas estão diretamente relacionados com a interrupção do sono. Destaca-se a irritabilidade e a dificuldade de concentração ou de memorização.

#### 2.5.1.3 Roncopatia

Frequente respiração ruidosa, muitas vezes com interrupções, sendo mais frequente quando está a dormir de barriga para cima. Pode estar associado a asfixia ou esmagamento.

### 2.5.2 Efeitos Cardiovasculares da Apneia de Sono

Um doente com Apneia do Sono irá apresentar um quadro crónico com múltiplas apneias e um baixo valor de oxigénio no sangue durante a noite, com despertares noturnos frequentes, entre outros sintomas e sinais, o que irá provocar ou estimular vários mecanismos, que a longo prazo se poderão tornar prejudiciais para o organismo.

As Apneias ocorrem repetidamente durante a noite e são acompanhadas por uma elevação simpática nos vasos sanguíneos periféricos, provocando vasoconstrição. No final de uma apneia mais prolongada, a pressão arterial (PA) pode atingir níveis elevados. Devido a esta correlação entre Apneia do Sono e o sistema cardiovascular, esta é considerada uma causa importante para a morbilidade e a mortalidade.

## 2.6 Diagnóstico

O diagnóstico da Apneia do Sono não é fácil, pois frequentemente a doença passa despercebida ou existe desconhecimento por parte do indivíduo acerca da mesma. A polissonografia é o teste definitivo para o diagnóstico, mas os testes de sono usando menos parâmetros (screening), p.e ECG, EEG ou SpO<sub>2</sub>, mais simples, também podem estabelecer o diagnóstico de Apneia de Sono, em casos específicos.




Figura 2.1: Exemplo de um exame de polissonografia.

### 2.6.1 Polissonografia

Atualmente, é o teste mais aceite, sendo considerado *Gold Standard*, permitindo estabelecer correlações úteis com os sintomas e queixas referidas pelos doentes. Este estudo ocupa uma noite inteira, que o doente deve realizar num hospital ou em clínica especializada, sob a vigilância de um cardiopneumologista. A polissonografia (PSG) pode incluir:

- **Electroencefalograma:** diferencia o sono de vigília.
- **Electrooculograma:** ajuda a determinar o sono/vigília e a perceber o sono - Rapid Eye Movement (REM).
- **sensor de respiração:** Isto é usado para determinar se a cessação do fluxo é devido à obstrução ou por ausência de movimento respiratório.
- **gravação de Electromiografia da atividade de membro e a atividade muscular de queixo:** Usado principalmente para determinar a presença de movimentos periódicos dos membros e ajuda com a determinação do estágio de sono/vigília.
- **capnografia:** pode ajudar a avaliar os efeitos de hipoventilação;
- **electrocardiograma;**
- **oximetria de pulso:** controla o nível da pressão de oxigénio no sangue;
- **electromiografia dos músculos tibiais anteriores:** avalia o movimento das pernas;

Este diagnóstico é desvantajoso para o doente visto que o mesmo tem de dormir fora do seu local habitual e, além disso, o custo é muito elevado. Os limitados recursos disponíveis para diagnosticar e tratar estes pacientes também é um entrave a este diagnóstico. Então, para solucionar este problema vários métodos usando um sinal (electrocardiograma (ECG), oximetria de pulso, electroencefalograma, ...) [OPH<sup>+</sup>16] ou um conjunto de 2 ou mais sinais têm sido desenvolvidos para tornar o diagnóstico e o início do tratamento mais eficiente e menos caro.

# Capítulo 3

## Estado da Arte

Neste capítulo irá ser feito um resumo dos estudos já feitos nesta área e que foram baseados para a realização desta mesma dissertação. Além disso, irá ser descrito os algoritmos de classificação usados e descrever um pouco do sinal ECG e da correlação do mesmo com a temática em estudo, a Apneia de Sono.

### 3.1 Introdução

Como já referido, o método tradicional de detecção de apneia é muito dispendioso e desconfortável. Assim, investigadores tentaram encontrar métodos de detecção de apneia mais confortáveis. Um desses métodos é através do sinal ECG. Estes estudos usam quase todos os mesmos métodos de pré-processamento, diferindo ao nível de extração das características e dos classificadores usados. Como tal, têm níveis de sucesso diferentes.

Neste capítulo, irá ser descrito o que foi descoberto sobre este projeto, além das suas potencialidades e limitações. Este capítulo contém as seguintes secções:

- secção 3.2 – **Combinação de Classificadores** – apresenta um estudo comparativo entre diferentes classificadores.
- secção 3.3 – **Seleção das Características** – apresenta um estudo em que foi realizada uma selecção de características para obter um melhor resultado.
- secção 3.4 – **Detecção de Apneia Usando Adaptative Neuro Fuzzy Inference System** – apresenta um estudo recorrendo ao classificador Adaptative Neuro Fuzzy Inference System (ANFIS) para a detecção de apneia.
- secção 3.5 – **Detecção de Apneia em Tempo Real** – apresenta um método para a detecção de apneia em tempo real.
- secção 3.6 – **Recorrer ao CMORWT-Based Feature of Time-Frequency Area** – apresenta um método de extração de características, CMORWT, para a detecção de apneia de sono.
- secção 3.7 – **Detectar Apneia do Sono com Linear Discriminant e Quadratic Discriminant** – apresenta um estudo em que os classificadores usados foram o Linear Discriminant(LD) e o Quadratic Discriminant (QD).
- secção 3.8 – **Rede neuronal para detectar Apneia do Sono** – apresenta uma rede neuronal como classificador para a detecção de apneia de sono.
- secção 3.9 – **Detecção de apneia do sono usando Least-squares Support Vector Machine** – apresenta como classificador o Least-squares Support Vector Machine (LS-SVM) como alternativa para a detecção de apneia.
- secção 3.10 – **Detecção de Apneia de Sono usando Extreme Learning Machine** – apresenta outro classificador para a detecção de apneia, sendo ele o Extreme Learning Machine (ELM).

- secção 3.11 – **Deteção de Artefactos para Deteção de Apneia de Sono** – apresenta um estudo onde foi classificado o sinal usando um algoritmo de deteção de artefactos para a sua classificação.
- secção 3.12 – **Técnicas de Classificação** – apresenta um resumo descritivo das técnicas de classificação usadas no estudo.
- secção 3.13 – **ECG e Apneia de Sono** – apresenta um resumo do são as utilidades do sinal ECG, assim como a correlação existente entre o mesmo e a deteção da apneia de sono.
- secção 3.14 – **Conclusões** – contém todas as conclusões retiradas a partir dos estudos apresentados nas secções anteriores, potencialidades das técnicas de classificação e do estudo proposto por esta dissertação.

## 3.2 Combinação de Classificadores

Em [XM12], é apresentada uma abordagem com combinação de classificadores. Aqui apresenta-se um comparativo entre classificadores e depois um comparativo entre duas combinações de classificadores.

O teste deste método foi feito usando uma base de dados do Hospital/University College Dublin Sleep Apnea Database (UCD database). Depois, foi realizado um processamento de sinal e de extração de características usando bibliotecas de MATrix LABoratory (MATLAB). De seguida, eles propõem-se a realizar uma selecção de características seguindo o cálculo "merit of a subset" que é calculado como:

$$M_s = \frac{kr_{cf}^-}{\sqrt{(k+k(k-1)r_{ff}^-)}}, \quad (3.1)$$

onde  $k$  é o número de características em  $S$ ;  $r_{cf}^-$  é a média da correlação classe-característica e  $r_{ff}^-$  é a média da intercorrelação característica-característica.

Posteriormente, estes realizam a classificação usando 10 classificadores entre os quais se encontram o Support Vector Machine (SVM), k-Nearest Neighbours (kNN) e o AdaBoost, entre outros, de forma individual. Neste estudo, para comparar os resultados eles usam três métricas, sendo elas a precisão, a especificidade e a sensibilidade. A sensibilidade é a habilidade de o software detectar correctamente a apneia de sono naquele momento. A especificidade é a capacidade de detectar correctamente os momentos sem apneia de sono, ou seja, considerados normais. A precisão é a percentagem de acerto, tanto dos momentos de apneia ou dos momentos sem apneia.

Na classificação individual, estes investigadores obtiveram, como melhor resultado no teste, uma especificidade de 80.29% e precisão de 77.74%, correspondente ao algoritmo de Bagging.REPTree e como melhor sensibilidade, um resultado de 72.47% correspondente ao algoritmo de Bagging.ADTree.

A partir destes resultados, eles partiram para uma combinação de classificadores, realizando duas combinações, uma composta por Bagging.REPTree + AdaBoost + kNN e outra composta por Bagging.REPTree + AdaBoost + Decision Table. Os resultados foram satisfatórios, pois nesta combinação estiveram sempre acima dos 80%, sendo os melhores resultados correspondentes a 83.61% de sensibilidade, 80.16% a especificidade e 81.00% para a precisão, sendo este método um método bastante satisfatório para a deteção de apneia de sono.

## 3.3 Seleção das Características

Em [GSF14], é apresentado um método diferente, usando selecção de características e para classificação do sinal usaram uma rede neuronal.

## Classification Models for Sleep Apnea Detection and/or Prediction

Estes investigadores usaram a base de dados publicada no PhysioBank. Esta base de dados consiste em 70 registos, que dividiram equitativamente entre aprendizagem e teste. Cada registo contém um sinal ECG que varia entre 7 e 10 horas.

Primeiro, estes investigadores fizeram detecção do complexo de QRS para daí poderem extrair o Heart Rate Variability (HRV), que é o intervalo entre dois batimentos consecutivos, ou seja, o intervalo entre dois pontos R, de forma a poderem retirar as características do sinal. Estas características são, por exemplo, a média do HRV, o desvio padrão, entre outras. Estes métodos foram realizados usando bibliotecas incorporadas no PhysioBank. De seguida, realizaram a selecção das características, usando para isso matrizes de correlação. Para classificar o sinal, usaram a biblioteca de MATLAB, Neural Network, que produziu uma Feedback Propagation Neural Network, composta por 9 neurónios de input, 6 neurónios na camada escondida e 2 neurónios de Output. Estes dois neurónios de Output representam as classes Apneia e Saudável. A função de activação usada foi a Tangent Sigmoid (tangent),

$$tansig(n) = \frac{2}{1 + e^{-2n}} - 1. \quad (3.2)$$

Este estudo apresenta uma precisão de acerto de 96%, o que é um resultado muito bom. Um apontamento será a falta dos valores de sensibilidade e especificidade para podermos comparar com outros estudos, inclusive com o nosso. Apesar disso, pela precisão conclui-se que esta proposta é muito boa, conseguindo resultados muito bons, o que será um desafio aliciente tentar alcançar esta precisão.

### 3.4 Detecção de Apneia Usando Adaptive Neuro Fuzzy Inference System

O estudo [AB13], apresenta uma abordagem diferente, onde é usado a transformada de wavelet e o ANFIS para classificar o sinal.

Este estudo usou a base de dados publicada e disponível online no PhysioBank. Esta base de dados contém 70 registos de ECG, cada amostragem com 100 amostras por segundo, aproximadamente com 8 horas de sinal cada. Cada minuto de um sinal ECG tem uma anotação, 'A' ou 'N' que indica a presença ou não presença de momento de apneia, respectivamente.

Em relação aos métodos usados no estudo, estes investigadores começam por usar um filtro, denominado *band-pass filter*, que serve para calcular a derivação do sinal ECG-Derived Respiration (EDR). Este filtro foi realizado usando 0.2 Hertz (Hz) e 0.4 Hz. De seguida, extraíram as características usando a transformada de wavelet. Para um sinal  $x(t)$ , a decomposição da wavelet é dada por:

$$x(t) = \sum_{k=-\infty}^{+\infty} c_{N,k} \varphi(2^{-N}t - k) + \sum_{j=1}^N \sum_{k=-\infty}^{\infty} d_{j,k} 2^{-j/2} \Psi(2^{-j}t - k) \quad (3.3)$$

Em 3.3,  $c_{N,k}$  é a aproximação dos coeficientes no nível  $N$  e  $d_{j,k}$  ( $j = 1, \dots, N$ ) é o coeficiente de detalhe no nível  $j$ . A função  $\Psi(t)$  é uma *scaling function*, usada para extrair as características do sinal. Para classificar o sinal, é usado o ANFIS, que é um classificador como a rede neuronal mas com recurso a um *fuzzy inference system*. Este ANFIS, consiste em 5 camadas como mostra a 3.1.




Figura 3.1: Arquitetura ANFIS

Este estudo realizou dois tipos de classificações: uma com vectores de 1 minuto do sinal e outra com vectores de 3 minutos do sinal. Vamos nos focar nos resultados com vectores de 1 minuto porque será como iremos proceder. Neste estudo, o melhor resultado alcançado foi de 90.1%. Assim como no estudo anterior, a falta do cálculo da sensibilidade e especificidade para comparação é uma falha, mas em termos de precisão é um resultado bastante alicianate para alcançar.

### 3.5 Detecção de Apneia em Tempo Real

O estudo [BMT11] apresentado a seguir implementa uma abordagem para um sistema de monitorização em tempo real, ou seja, apresenta uma solução mais rápida e mais eficiente em termos computacionais.

A base de dados usada neste estudo foi a base de dados publicada e disponível pelo PhysioBank. Como já referido, é composta por 70 registos de ECG, cada amostragem com 10 amostras por segundo, aproximadamente com 8 horas de sinal cada. Cada minuto tem uma anotação de 'A' ou 'N' que indica presença ou não presença de momento de apneia, respectivamente.

O processamento do sinal é feito de forma automática usando a Undecimated Lifting Wavelet Transform (ULWT), que possui um reduzido custo computacional comparado com outros métodos. Também usaram a Daubechies/D4 wavelet para minimizar a ordem da filtragem e consequentemente reduzir o custo computacional. Com o uso deste wavelet, é possível extrair o complexo de QRS. De seguida, extraem o EDR e o HRV. O EDR é calculado através da amplitude da onda R quando a onda T não é detetada. O HRV é calculado através do intervalo R-R. A partir destas duas medidas extraíram as características.

As características são divididas através das duas medidas. No HRV, as características são a média, desvio padrão, entre outras e no EDR as características são apenas a média e o desvio padrão. Para classificar o sinal é usado o SVM. O resultado deste estudo foi muito positivo com a precisão mais alta 96% com uma sensibilidade de 96% e especificidade 84.76%.

### 3.6 Recorrer ao CMORWT-Based Feature of Time-Frequency Area

Em [SW15], é apresentado uma abordagem diferente apenas no método de extração de características, recorrendo a um componente de tempo-freqüência e utilizando, para classificar o sinal, o classificador SVM.

Este método, inicialmente realiza um pré-processamento, realizando primeiro uma filtragem mediana em janelas de 200 milissegundos (ms) e outra de 600 ms. De seguida, detectam a onda R através do método Wavelet Transformation Modulus Maxima (WTMM).

## Classification Models for Sleep Apnea Detection and/or Prediction

O cálculo do HRV é realizado através do intervalo entre dois batimentos cardíacos consecutivos, ou seja, o intervalo entre dois pontos R que é calculado do seguinte modo:

$$rr(i) = r(i+1) - r(i), i = 1, 2, \dots, n-1 \quad (3.4)$$

onde  $r(i)$  é o ponto R na posição  $i$ .

O cálculo do EDR é computado através da área da onda R, que é o método mais usado para calcular o EDR. Para o calcular, procura-se o valor mais baixo dentro de 100 ms e o mínimo valor de um ponto R. De seguida, calcula-se a área desta onda para obter o EDR.

Para calcular o valor da componente tempo-frequência do EDR e do HRV é usado o CMORWT, que é uma transformada de wavelet. A função principal da wavelet CMORWT é definida como:

$$\Psi_0(\eta) = \Pi^{-1/4} e^{i\omega_0\eta} e^{-\eta^2/2} \quad (3.5)$$

onde  $\omega_0$  é a "characteristic eigen-frequency". A wavelet  $\Psi_{\Gamma,d(f)}$  é computada com o factor de controlo  $\omega = (t - \Gamma)/d(f)$ , ( $f$  é a frequência principal).  $d(f)$  pode ser computado como:

$$d(f) = \frac{\omega_0 + \sqrt{2 + \omega_0^2}}{4\pi f}. \quad (3.6)$$

Sendo  $S(t)$  o sinal do EDR e do HRV obtido do ECG, a componente de wavelet  $x(f, \Gamma)$  no tempo  $\Gamma$  e frequência  $f$  é computado como:

$$x(f, \Gamma) = \|S(t) * \Psi_{\Gamma,d(f)}(t)\| \quad (3.7)$$

para  $f < 0.01, 0.02, \dots, 0.4$  Hz.

Para a classificação, como referido anteriormente, foi usado o SVM. Os dados de input foram os componentes obtidos através do cálculo do CMORWT. Este estudo conseguiu obter, como melhor resultado, uma sensibilidade de 85% e 99% de especificidade. Isto mostra a grande viabilidade deste método, pois obtiveram resultados muito positivos.

### 3.7 Detectar Apneia do Sono com Linear Discriminant e Quadratic Discriminant

O estudo [dCHS<sup>+</sup>03] apresenta um método de classificação diferente de toda a literatura em que é implementado dois classificadores, o LD e o QD, até então não usados na literatura.

A base de dados usada neste estudo foi mais uma vez a base de dados disponível no PhysioBank, tal como referido anteriormente. Para detectar o complexo de QRS, este estudo optou por uma detecção automática seguida de uma detecção manual por especialistas. Isto foi realizado para fazer comparações em separado dos dois métodos de detecção manual, para determinar a importância da detecção do complexo de QRS da forma mais completa possível. A partir destes valores, calcularam o intervalo RR, composto pela diferença entre dois pontos consecutivos no complexo de QRS. O EDR foi calculado através da área da onda R numa região de 100 ms.

## Classification Models for Sleep Apnea Detection and/or Prediction

As características extraídas do intervalo RR são a média, desvio padrão, entre outras, enquanto a partir do EDR foram extraídas a média, o desvio padrão e o Power Spectral Density (PSD) do sinal EDR. O EDR contém 36 características extraídas e o intervalo RR contém 52 características.

Para classificar o sinal, como já referido no início desta subsecção, foram o LD e o QD. Um total de  $N$  vectores de características estão disponíveis para uso do classificador. O número de vectores de características disponíveis para treino da classe  $k$  é  $N_k$ , e, consequentemente,

$$N = \sum_{k=1}^c N_k, \quad (3.8)$$

onde  $c$  é as possíveis classes.

O  $n$ ésimo vector de características na classe  $k$  é designado como  $x_{nk}$ . O método de treino para ambos os modelos envolve determinar a classe condicional média dos vectores  $\mu_k$  usando,

$$\mu_k = \frac{1}{N_k} \sum_{n=1}^{N_k} x_{nk}. \quad (3.9)$$

Para o classificador LD a matriz de covariância é calculada usando,

$$\Sigma = \frac{1}{N-c} \sum_{k=1}^c \sum_{n=1}^{N_k} (x_{nk} - \mu_k)(x_{nk} - \mu_k)^T. \quad (3.10)$$

Para o classificador QD as matrizes de covariância,  $\Sigma_k$ , é calculada como,

$$\Sigma_k = \frac{1}{N_k - 1} \sum_{n=1}^{N_k} (x_{nk} - \mu_k)(x_{nk} - \mu_k)^T. \quad (3.11)$$

Para classificar um vector  $x$ , os valores são assumidos para as probabilidades prévias  $\Pi_k$  e os valores discriminantes para cada classe são calculados usando

$$y_k = -\frac{1}{2} \mu_k^T \Sigma^{-1} \mu_k + \mu_k^T \Sigma^{-1} x + \log(\Pi_k) \quad (3.12)$$

para o classificador LD e

$$y_k = -(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k) + 2 \log(\Pi_k) - |\Sigma_k^{-1}| \quad (3.13)$$

para o classificador QD.

Para determinar a classe, é usado a fórmula seguinte,

$$P(k | x) = \frac{\exp(y_k)}{\sum_{l=1}^c \exp(y_l)} \quad (3.14)$$

A classe final é a classe com maior probabilidade, ou equivalente, ao maior valor discriminante. Além disto, ainda realizaram uma selecção das características, para ver se iriam melhorar a performance do classificador. O melhor resultado, sem selecção de características, foi de 92.3% de precisão, 89.6% de sensibilidade e

## Classification Models for Sleep Apnea Detection and/or Prediction

94% de especificidade e com selecção de características foi de 92.2% de precisão, 89.8% de sensibilidade e 93.7% de especificidade. Podemos concluir que, com este método, foram obtidos resultados muito bons, muito precisos e muito difíceis de alcançar.

### 3.8 Rede neuronal para detectar Apneia do Sono

Em [KGP08], foi realizado um estudo dividido em três estágios e comparando a performance da rede neuronal para cada um dos estágios, sendo a rede neuronal diferente para cada um destes.

A base de dados usada foi uma base de dados recolhida pelos investigadores deste estudo. Esta contém 33 pacientes e o sinal ECG contém 250 amostras por segundo. Este sinal foi filtrado a 1 Hz e a 100 Hz.

No primeiro estágio, foi realizada a detecção de eventos. Cada período do sinal ECG foi decomposto em 8 níveis de coeficientes usando a wavelet Symlet. De cada nível, foram extraídas as características, tais como a média, entropia de Shannon, variância, entre outras, extraíndo no total 45 características. A rede neuronal usada para classificar o sinal foi composta por 33 neurónios na camada escondida (hidden layer). Este obteve como resultado uma sensibilidade de 87.64%, uma especificidade de 95.10% e uma precisão de 95.10%.

No segundo estágio, usaram novamente as características extraídas no primeiro estágio, mas para reduzir as características e para poderem trabalhar com as melhores características, usaram novamente a Symlet e calcularam a área da curva Característica de Operação do Receptor (ROC). Isto resultou em 27 características, contendo média, variância, entre outras. A rede neuronal era composta por 23 neurónios na camada escondida e obteve resultados de precisão de 83.40%, 86.12% de sensibilidade, 78.12% de especificidade.

No terceiro estágio, eles usaram um método para extrair apenas as melhores 9 características. Esse método foi a distância de Mahalanobis aplicada à curva ROC. A rede neuronal foi construída apenas com 7 neurónios na camada escondida e levou a um resultado de 93.72% na sensibilidade, 99.16% na especificidade e 98.96% na precisão.

Este estudo obteve três resultados muito bons, e irá servir como ponto de comparação com o nosso estudo, pois como iremos usar redes neuronais podemos fazer aqui uma comparação e estabelecer as metas para alcançar os resultados deste estudo.

### 3.9 Detecção de apneia do sono usando Least-squares Support Vector Machine

O estudo [VTB<sup>+</sup>13] é uma abordagem semelhante a estudos já apresentados anteriormente, mas, com um classificador diferente, interessante, que é o LS-SVM.

Este estudo recorreu a duas bases de dados. A primeira foi a Apnea-ECG database publicada no PhysioNet. A segunda consiste em 10 sinais ECG extraídos de um PSG de 10 pacientes diferentes, no Hospital Universitário de Leuven, na Bélgica. Estes são amostrados a 200 Hz e também foram anotados manualmente por especialistas.

Cada minuto do sinal ECG foi processado com recurso ao algoritmo Pan-Tompkins, que serve para identificar todas as ondas R. Adicionalmente, foi aplicada uma pesquisa do fim do sinal para o início, para identificar todos os possíveis batimentos que não foram detectados. Assim, que foram detectados todas as ondas R, procederam ao cálculo do HRV.

Depois de identificar todos os pontos R e de calcular o HRV, três diferentes metodologias, Principal Component Analysis (PCA), amplitude dos pontos R e kernel Principal Component Analysis (kPCA) foram implementadas para computar o sinal EDR.

Para classificar cada minuto de um sinal ECG, foram retiradas as características do sinal através do HRV e do EDR. A partir do HRV foram extraídas a média, desvio padrão, entre outras, e a partir do EDR apenas a média e o desvio padrão foram extraídas. Depois, eles usaram o PCA para seleccionar as melhores características para dar entrada no LS-SVM.

Para classificar o sinal ECG foi utilizado, como referido anteriormente, o LS-SVM e obtiveram como melhor resultado uma sensibilidade de 88.84%, 83.29% de especificidade e 85.07% de precisão. Este método teve um bom resultado, tendo em conta que implementaram um método cuja performance a nível de hardware não é tão exigente, o que leva a uma boa solução para sistemas de monitorização que o paciente pode levar para casa.

### 3.10 Detecção de Apneia de Sono usando Extreme Learning Machine

O estudo apresentado em [SdC14], é semelhante a estudos apresentados anteriormente, mas apresenta um classificador diferente de todos os anteriores, denominado ELM.

A base de dados usada foi a disponível e publicada no PhysioBank, contendo 70 registos a 100 Hz e cada minuto anotado manualmente por um especialista com os valores de 'A' ou 'N' no caso de haver presença de um momento de apneia ou não, respectivamente.

Primeiro, aplicaram pré-processamento ao sinal, aplicando uma filtragem mediana a 200 ms e a 600 ms ao sinal ECG original. De seguida, detectaram o complexo de QRS e os pontos R, calculando posteriormente o HRV como a diferença entre dois pontos R consecutivos. Depois, fizeram uma revisão dos pontos R, com um algoritmo, para obter pontos mais precisos. Agora, já estão prontos a extrair as características do sinal. Para as características foram seleccionadas a média, o desvio padrão e o PSD para o HRV e para o EDR. Estas características foram extraídas para cada minuto do sinal ECG, conseguindo extrair 68 características no total.

Estas características foram aplicadas como input para o classificador, o ELM. Este ELM, consiste numa rede neuronal feed forward com uma camada escondida e eles treinaram a rede com 1 a 10 nós na camada escondida. Este rede neuronal, é mais rápida na classificação e com menor erro no treino.

O melhor resultado foi obtido com 10 nós na camada escondida, levando a uma precisão de 87.7%, sensibilidade de 81.3% e especificidade de 91.7%, levando a um resultado positivo com uma especificidade muito elevada. Além de que este resultado foi obtido recorrendo a funções automáticas, sem haver recurso a especialistas para rever os pontos R calculados como em estudos anteriores, e também não houve selecção de características como na maior parte dos estudos referidos anteriormente.

### 3.11 Detecção de Artefactos para Detecção de Apneia de Sono

Apresento agora o estudo [VTB<sup>+</sup>12], que usa um método diferente de análise do sinal ECG, para extrair características e classificar o sinal, recorrendo aos artefactos do sinal.

A base de dados usada para realizar este estudo foi uma base de dados extraída de 16 registos ECG de 16 pacientes do laboratório no Hospital Universitário de Leuven (UZ Leuven), na Bélgica. Os sinais são a 200 Hz e variam de 4 a 11 horas. No total obtiveram 152 horas e 12 minutos de sinal ECG. Cada registo foi manualmente anotado por especialistas, correspondendo a ocorrências de apneia de sono ou não.

Primeiro, o sinal foi filtrado usando o filtro de Butterworth a 1 Hz e a 40 Hz. Depois deste pré-processamento a Autocorrelation Function (ACF) de cada segmento de ECG é obtida através da transformação de Fourier inversa do PSD.

Depois de calcular os ACF, necessitasse de localizar os segmentos contaminados. Para detectar os artefactos usa-se o algoritmo referido na 3.1 seguido da função cosseno 3.15 para calcular a similaridade entre cada

par de ACF.

$$\cos\theta = \frac{A_1^T A_2}{\|A_1\| \|A_2\|} \quad (3.15)$$

---

<b>Input:</b> ECG signal and length $N$ . In this study they use $N = 60s$ .
<b>Output:</b> Weight for each ECG segment and 95th percentile of the weights.
1. Segment for ECG into epochs of length $N$ .
2. Compute the ACF of each segment using the inverse Fourier transform of its corresponding PSD.
3. Calculate the cosine similarity 3.15 between each pair of ACF. This result in the similarity matrix between all ACF.
4. Compute the degree values by summing all the columns of the similarity matrix. These degrees correspond to the weights.
5. Calculate the 95th percentile of the weights.
6. Label the segments with weights outside the 95th percentile, as contaminated.

---

Tabela 3.1: Artefact Detection Algorithm

A nível de classificação, o resultado obtido foi de 90% de precisão, 90% de especificidade e 96% de sensibilidade. Uma solução bastante positiva, que não requer operações computacionais muito dispendiosas e um método muito fácil de implementar.

## 3.12 Técnicas de Classificação

### 3.12.1 Redes Neurais

Uma rede neuronal tem uma estrutura dividida em diferentes camadas. Cada camada consiste em unidades que recebem dados das camadas anteriores e enviam o seu *output* para as unidades imediatamente seguintes. A activação de uma *hidden unit* é uma função  $F_i$  dos *weighted inputs* mais o *bias*. O *output* de uma *hidden unit* é distribuído pela próxima camada de  $N_{i,2}$  *hidden units* até atingir a última camada de *hidden units*, os *outputs* são dirigidos para a camada de  $N_o$  *output units*.

Apesar da *back-propagation* poder ser aplicada a redes com qualquer número de camadas, [HSW89] demonstrou que apenas uma camada de *hidden units* é suficiente para aproximar qualquer função com um conjunto grande mas finito de descontinuidades de uma precisão arbitrária se as *hidden units* são não lineares [KSKS96].

O método por detrás da *back-propagation* é muito intuitivo. Quando um *learning pattern* é seguro, os valores de activação são propagados para os *output units*, e quando o *output* da rede atual é comparado com o *output* desejado, terminamos com um erro em cada *output units*. Mais, temos um erro  $e_o$  num particular *output unit*. O objectivo principal é aproximar este erro a zero. A forma mais simples de atingir isto é usando um método *greedy*. Basicamente, esforçamos a mudar as conexões da rede neuronal para que  $e_o$  seja zero para este particular *pattern*.

A rede neuronal com *feed-forward back propagation* tem duas fases: a primeira quando o *input*  $x$  é apresentado e propagado na rede originando os *outputs*  $y_o^p$  para cada *output unit*. A segunda fase consiste numa passagem para trás na rede, durante a qual o erro é passado a cada unidade e os pesos propriamente calculados novamente. Isto é feito até que se atinja uma performance aceitável.

### 3.12.2 Support Vector Machines (SVM)

O SVM implementa a seguinte ideia: mapeia os vetores de input no espaço  $Z$  através de um mapeamento não-linear escolhido *a priori*. Neste espaço, uma superfície de decisão linear é construída com propriedades especiais que asseguram a generalização da rede [CV95a]. Um *hyperplane* é construído no espaço correspondente ao espaço de alta dimensão.

Um *hyperplane* ótimo é definido como a função de decisão linear com margem máxima entre vetores de classes. Para construir tão ótimos hyperplanes, tem de se ter em conta o tamanho de dados para treino, os chamados *support vectors*, que determinam esta margem. Se os vetores de treino são separados sem erros por um *hyperplane*, o valor esperado da probabilidade de cometer um erro num exemplo teste é limitado pelo rácio entre o valor esperado do número de vetores de suporte e o número de vetores de treino.

Se o *hyperplane* ótimo for construído a partir de poucos *support vectors* relativamente ao tamanho dos dados de treino, a generalização irá ser alta - mesmo num espaço infinitamente dimensional.

Um dos maiores problemas do *hyperplane* é que mesmo que generalize com sucesso, o problema técnico de como trabalhar o espaço dimensional permanece. Isto permite a construção de classes de superfícies de decisão, por exemplo, superfícies de decisão polinomiais de grau arbitrário. Vamos chamar este tipo de *machine learning* de *support-vector network*.

O primeiro objetivo de desenvolver esta técnica é em separar os dados de treino sem erros. Depois, [CV95a] desenvolveram uma extensão para cobrir quando é impossível a separação sem erros. Com esta extensão, *support-vector networks* podem ser consideradas como uma nova classe de *learning machine*, tão poderosa e universal como as redes neuronais.

Em *machine learning*, *support vector machines* são modelos de aprendizagem supervisionada com algoritmos associados que analisam os dados usados para classificação e análise de regressão. O algoritmo traça cada item de dados como um ponto num espaço de dimensão  $n$ , onde  $n$  é o número de características no *dataset* com o valor de cada característica a ser o valor de uma coordenada particular. Depois, para proceder à classificação, o *hyperplane* que diferencia duas classes é calculado.

O problema está nos dados reais serem confusos e não poderem ser separados perfeitamente com o *hyperplane*.

A limitação em maximizar a margem da linha que separa as classes pode ser relaxada. Esta é costume de ser chamada de *soft margin classifier* e permite que alguns pontos nos dados de treino violem a linha de separação.

Um conjunto de coeficientes adicional são introduzidos e permitem dar uma margem de manobra à linha em cada dimensão. Estes coeficientes são por vezes chamados de *slack variables*. Isto aumenta a complexidade do modelo, pois existem mais parâmetros para o modelo ajustar os dados.

Para separar a parte remanescente dos dados de treino, um *hyperplane* ótimo de separação pode ser construído. A constante  $C$  é usada aqui com este objetivo. O parâmetro  $C$  é a constante onde o *hyperplane* minimiza o número de erros no conjunto de dados de treino e separa o resto dos elementos com uma margem máxima.

### 3.12.3 Linear Discriminant Analysis (LDA)

LDA é uma conhecida técnica para classificação e de redução de dimensionalidade de dados. Este classificador facilmente manobra o caso onde dentro da classe as frequências não são iguais, e as suas performances foram examinadas em dados de teste gerados aleatoriamente. Adicionalmente, maximiza o rácio da variância entre classes e a variância dentro da classe num *dataset* qualquer, garantindo assim a máxima separabilidade.

Há duas abordagens diferentes para o LDA: transformação dependente da classe e transformação independente da classe. Enquanto que na dependente da classe, o objetivo é maximizar o rácio da variância entre

## Classification Models for Sleep Apnea Detection and/or Prediction

classes e a variância dentro da classe, na independente da classe, o objetivo é maximizar o rácio da variância total e a variância entre classes.

### 3.12.4 Partial Least Squares Regression (PLS)

Partial least squares regression é um método estatístico que generaliza e combina características do Principal Component Analysis (PCA) e Multiple Regression. É praticamente útil a prever um conjunto de variáveis dependentes de um (grande) conjunto de variáveis independentes (i.e., predictors).

O objectivo do PLS é prever Y por X e descrever a sua estrutura comum. Quando Y é um vector e X um "full rank", este objectivo pode ser cumprido usando "Ordinary Multiple Regression".

### 3.12.5 Regression analysis (REG)

Em modelação estatística, a "Regression analysis" é um conjunto de processos estatísticas para estimar as relações entre variáveis, quando o foco é a relação entre a variável dependente e uma ou mais variáveis independentes (ou "predictors"),

"Regression analysis" é largamente usado para previsão e *forecasting*. Também é usada para compreender quais, dentro das variáveis independentes, estão relacionadas com a variável dependente, e para explorar as formas destas relações.

### 3.12.6 Wiener-Hopf

O método Wiener-Hopf é uma técnica matemática largamente usada em matemática aplicada. Foi inicialmente desenvolvido como um método para resolver equações integrais, mas é largamente usado para resolver equações parciais bi-dimensionais com condições mistas no limite no mesmo limite.

Em geral, as condições de limite são transformadas e essas transformações são usadas para definir um par de funções complexas que são analíticas respectivamente nas metades superior e inferior do plano complexo e não têm crescimento mais rápido do que polinómios nessas regiões. Estas duas funções também coincidem em alguma região do plano complexo, tipicamente, uma tira fina contendo a linha real.

### 3.12.7 Augmented Naive Bayesian Classifier (aNBC)

A Augmented Naive Bayesian Network, mantém a estrutura da rede Naive Bayesian e aumenta-a adicionando arestas entre as variáveis para capturar as correlações entre os atributos. Mas estes processos aumentam a complexidade computacional.

Para reduzir a complexidade computacional e também ter em conta as correlações entre as variáveis, restrições têm de ser impostas no nível de interacção entre variáveis.

### 3.12.8 Perceptron Learning Algorithm (PLA)

Em inteligência artificial, um *perceptron* é um algoritmo para aprendizagem supervisionada para classificadores binários (funções que decidem se um input, representado por vector de números, pertencem a uma classe ou não). É um tipo de classificador linear, i.e. um algoritmo de classificação que faz predições baseadas numa função linear combinando um conjunto de pesos com um vector de características.

O PLA é um exemplo de aprendizagem supervisionada com reforço. Algumas das suas variantes usam correção do erro.

### 3.12.9 Least mean squares (LMS)

O LMS tem sido aplicado a uma variedade de áreas. É mais difícil de analisar, pois é um algoritmo adaptativo "stochastic", do que o método determinístico.

O LMS é baseado no uso de estimação instantânea da função de autocorrelação e das funções de correlações cruzadas.

## 3.13 ECG e Apneia de Sono

### 3.13.1 ECG

Electrocardiografia (ECG) é o processo que grava a atividade elétrica do coração durante um período de tempo usando eletrodos colocados sobre a pele. Estes eletrodos detetam alterações elétricas que surgem no músculo do coração durante cada batida. Este processo é não-invasivo, barato e extremamente versátil que pretende obter informação relacionada com o coração, como a sua anatomia, o tamanho das câmaras cardíacas ritmo e alterações na condução, alterações na concentração de eletrólitos, a extensão, localização e progressão de lesões da isquemia do miocárdio e a influência de certo tipo de medicação [SL]. Este método é até agora o melhor para analisar distúrbios do ritmo cardíaco [SL].

Baseado no sinal ECG, uma miríade de componentes podem ser obtidas. A primeira deflexão superior é a onda P, refletindo a despolarização atrial. A despolarização ventricular é representada pelo complexo QRS. A onda Q é a primeira deflexão negativa desde a linha base depois da onda P, mas precedendo por uma deflexão superior, a onda R que é a primeira deflexão positiva depois da onda P, refletindo a despolarização da massa ventricular. A onda T reflete a re-polarização dos ventrículos e podem representar também positiva ou negativa deflexão depois do complexo de QRS. A área dentro da onda T aproxima-se da do complexo QRS, e a sua polaridade é fortemente igual à polaridade principal do complexo de QRS. O intervalo de QRS é o intervalo entre o início da onda Q e o fim da onda S, incorporando a despolarização ventricular, e o segmento ST é a porção do registo, geralmente representada por uma linha horizontal, desde o fim da despolarização ventricular, quer representada por uma onda R ou por uma onda S, até ao início da onda T [SL].

A análise de um gráfico de ECG inclui a análise de padrões e características técnicas, a medição da frequência cardíaca, ritmo, intervalo PR, voltagem do complexo QRS e a análise da progressão das ondas R e T em derivações precordiais.

Este sinal é importante para detetar e prever diversas doenças cardíacas.




Figura 3.2: Representação do complexo QRS e do sinal ECG.

### 3.13.2 Apneia do Sono através do ECG

McNames and Fraser descobriram que a frequência cardíaca, a amplitude da onda S e a energia de pulso do sinal ECG são características informativas para a detecção de apneia de sono, assim como o ECG, que podem representar uma útil e importante ferramenta para ajudar os médicos no processo de decisão [MF00]

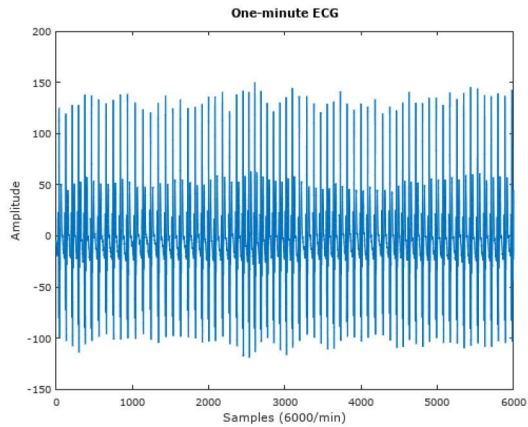


Figura 3.3: Exemplo de um momento normal num sinal ECG com a duração de um minuto.

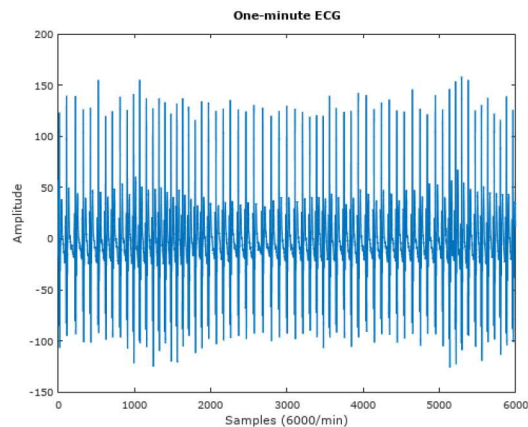


Figura 3.4: Exemplo de um momento de apneia do sono num sinal ECG com a duração de um minuto.

Analisando os dois exemplos, 3.3 e 3.4, o que salta a vista é a mudança na frequência cardíaca. Depois, nota-se a mudança de amplitude nas diferentes ondas e a mais alta amplitude na onda S quando o momento de apneia está a ocorrer. A partir daqui, podemos determinar que a partir do sinal ECG, podemos, realmente, detetar apneia do sono e desenvolver um método promissor de decisão clínica, apontando à melhoria da qualidade dos diagnósticos.

Em linha com isto, as hipóteses que o ECG apenas é um método promissor no uso de deteções de apneia de sono precisa de ser testado. Para estudar esta hipótese, foi desenvolvido um sistema para detetar apneia de sono usando diferentes componentes e métodos:

- Sgolay-filter;
- TEO algorithm;
- Extração de características (HRV e EDR);
- Classificação;

- Rede Neuronal;
  - SVM;
  - LDA;
  - Gath-Geva;
  - PNN.
- Seleção de Características

### 3.14 Conclusões

Podemos concluir que estes métodos ainda necessitam de melhoramentos, principalmente ao nível de ser mais automatizado e com menor necessidade de recursos de hardware. Mas, olhando para o que foi apresentado neste capítulo, já existem soluções interessantes e com bastante potencial, o que leva a um esforço maior para atingir melhores resultados do que aqueles que já foram apresentados.

# Capítulo 4

## Tecnologias e Ferramentas Utilizadas

### 4.1 Introdução

Para a realização deste estudo foi necessário recorrer a diferentes tecnologias e dados. Neste capítulo, irão ser descritas todas as tecnologias e ferramentas usadas para o processamento de sinal, extração de características e classificação do sinal, assim como para o desenvolvimento de todo o estudo. Todas as tecnologias, linguagens de programação e funções usadas irão ser descritas, assim como os dados usados. Este capítulo contém as seguintes secções:

- Secção 4.2 – **Linguagem de Programação Usada** – apresenta a linguagem de programação usada assim como o porquê da sua escolha.
- Secção 4.3 – **Dados usados para Análise** – descreve a base de dados utilizada para realizar os testes, o treino e a validação.
- Secção 4.4 – **Conclusões** – Concluí o capítulo e apresenta todas as reflexões acerca das tecnologias e ferramentas.

### 4.2 Linguagem de Programação

A linguagem de programação escolhida para o desenvolvimento desta solução foi o GNU Octave que é uma linguagem de alto nível. Esta providencia capacidades para soluções de problemas lineares e não lineares e para realizar operações de visualização e manipulação de dados. Esta linguagem é muito similar a MATLAB. A escolha desta linguagem deveu-se à capacidade de desenvolver a solução de forma mais rápida pois produz-se código de forma muito rápida e, além disso, as funções e pacotes que disponibiliza ajuda num mais rápido desenvolvimento.

#### 4.2.1 Funções e Pacotes Usados

Para a realização deste estudo e desta solução, foi necessário recorrer a vários pacotes do Octave. Estes pacotes contêm funções para auxiliar e tornar mais rápida a implementação do projecto na sua totalidade.

Para o processamento do sinal foi utilizado o pacote *Signal*. Neste pacote, usou-se a função *sgolayfilt* para filtragem do sinal ECG. O pacote *NaN* foi necessário para recorrer à função *mean*, de modo a realizar médias, *std* para o desvio padrão e à *rms* para cálculo do *root mean square*. O pacote *specfun* para uso da função *heaviside*, de forma a extrair algumas características do sinal e ao pacote *communications* para a função *isempty* que verifica se uma matriz está vazia.

Para a rede neuronal, foi usado o pacote *statistics* para recurso à função *nanmean* e *isnan*. Para a rede, recorreu-se ao pacote *nnet*, que fornece as funções *newff*, *trastd*, *prestd*, *train*, *subset*, *min\_max* e *tansig* e *purelin* necessárias para o desenvolvimento da rede neuronal e sua configuração.

### 4.3 Dados usados para Análise

Neste estudo, recorreu-se a uma base de dados disponível online no Physionet. Ela é composta por 70 sinais, mas apenas 35 foram usados pois são os que contêm anotações sobre os momentos de apneia. Cada sinal foi gravado a 100 Hz e tem aproximadamente 8 horas de duração, com anotações a cada minuto. Alguns destes sinais foram adquiridos em conjunto com sinais respiratórios. As anotações foram feitas por especialistas usando o sinal respiratório como critério para a análise. Cada minuto foi anotado com 'A' ou 'N' no caso de apneia de sono ou momento normal, respectivamente.

### 4.4 Conclusões

A escolha da base de dados deveu-se à sua publicação e disponibilidade para download gratuito, não necessitando de realizar exames em pacientes, uma vez que atrasaria a realização do projecto. Esta base de dados facilitou e tornou mais rápido o começo da implementação do projecto.

A escolha da linguagem de programação facilitou a implementação e diminui o tempo despendido na mesma. Estas ferramentas permitiram um desenvolvimento mais rápido e mais fácil, ajudando a despendar tempo em tarefas que necessitam de uma maior análise.

# Capítulo 5

## Implementação e Testes

### 5.1 Introdução

A implementação do projecto deveu-se à pesquisa e no que a literatura já tinha de informação. Toda a base do projecto vem baseando-se na literatura e no estado da arte e que foi reproduzido na tentativa de verificar a viabilidade do estudo e na possibilidade de melhoria dos estudos do estado da arte.

Neste capítulo é apresentado toda a implementação do sistema de detecção de apneia de sono, decisões feitas, os resultados, afinações e dificuldades encontradas na resolução deste sistema.

Este capítulo contém as seguintes secções:

- secção 5.2 – **Leitura dos dados** – onde é descrito detalhadamente o processo de leitura de cada ficheiro ECG.
- secção 5.3 – **Deteção do complexo QRS** – apresenta os métodos realizados no processamento do sinal e o método de detecção do complexo QRS.
- secção 5.4 – **Extracção das Características** – apresenta quais as características extraídas e todos os métodos utilizados na extração destas através do HRV e do EDR.
- secção 5.5 – **Seleção de Características** – apresenta métodos automáticos de selecção de características para obtenção de melhores resultados.
- secção 5.6 – **Classificação** – apresentada detalhadamente a classificação do sinal. Descreve todos os algoritmos usados na classificação e a sua implementação. Apresenta todos os resultados obtidos.
- secção 5.9 – **Conclusão** – onde são apresentadas as conclusões sobre os resultados obtidos na secção 5.6.

### 5.2 Leitura da Base de Dados

O sistema foi avaliado na base de dados disponível *online* PhysioNet, denominada apnea-ecg database. Esta base de dados consiste em 70 registos, mas apenas 35 registos foram usados pois são os únicos que contêm anotações. Cada registo está a 100 Hz e é de duração de aproximadamente 8 horas, com anotações a cada minuto. Os registos foram adquiridos com sinais respiratórios. As anotações foram feitas por especialistas em doenças do sono usando como critério o sinal respiratório. Cada minuto foi anotado com 'A' ou 'N' no caso de um momento de apneia ou não, respectivamente.

### 5.3 Deteção do complexo de QRS

A deteção QRS é uma parte muito importante no trabalho pois é de onde as características são extraídas. Antes desta detecção o sinal terá de estar livre de ruído, como a *baseline wander*, que é uma frequência baixa, que torna difícil interpretar o sinal ECG, porque a existência de ruído leva ao decréscimo da performance dos classificadores.

## Classification Models for Sleep Apnea Detection and/or Prediction

Assim, o filtro *sgolay* foi usado para suavizar o sinal. Com o ECG livre de ruído, é possível, agora, detectar as ondas R e o complexo QRS sem falhar um batimento.

A detecção da onda R foi feita recorrendo ao algoritmo TEO, que é definido como:

$$\Psi[x(t)] = \left(\frac{dx(t)}{dt}\right)^2 - x(t)\frac{d^2x(t)}{dt^2}. \quad (5.1)$$

Este algoritmo é aplicado ao sinal através da versão discreta, definida como:

$$x(n) - x(n-1) - x(n)^2 + 2x(n)x(n-1) - x(n)x(n-2) \quad (5.2)$$

O código apresentado em mostra a aplicação da função discreta do algoritmo Teager Energy Operator (TEO), sobre o sinal ECG.

Listing 5.1: Algoritmo TEO.

```
for n = 3 : m-1
    w(n) = z(n)-z(n-1)-z(n)^2 + 2 * z(n) * z(n-1) - z(n)*z(n-2);
endfor
```

Para detectar os pontos R, o sinal terá de ser processado dentro de uma janela de 1 segundo de cada vez. De seguida, calcula-se o máximo valor nessa janela e aplicamos um *threshold* para termos a certeza que capturamos todos os pontos e eliminamos falsos pontos R. Se o resultado obtido exceder o limite num certo tempo, por exemplo,  $t_0$  e mais nenhum valor o exceder nos próximos 0.5 segundos, então este ponto é considerado um ponto R também.

O código que realiza esta detecção dos pontos R está descrito em 5.2.

Listing 5.2: Algoritmo de detecção dos pontos R.

```
for i = 1 : 100 : m-1
    for p = i : (i+100)
        if (p>m-1) break
        endif
        if (w(p)>max1)
            max1 = w(p);
        endif
    endfor
    j = i;
    while j < (i+100)
        if (j>m-1) break;
        endif
        if (w(j) > 0.10 * max1)
            max2 = w(j);
            x = j;
            for k = j : (j+25)
                if (k>m-1) break;
                endif
                if (w(k)>0.10 * max1)
                    if (w(k)>max2)
```

## Classification Models for Sleep Apnea Detection and/or Prediction

```
        max2 = w(k);
        x = k;
    endif
    endif
endfor
teo_algorithm(x) = max2;
j = k;
else
    j = j + 1;
endif
endwhile
endfor
```

### 5.4 Extração das características

A extração das características foi processada numa janela de 1 segundo do sinal ECG, relativamente ao HRV e ao sinal EDR.

O HRV é o ciclo de um batimento cardíaco, ou seja, o intervalo de tempo entre dois pontos R consecutivos. É calculado através de:

$$rr(n) = r(n+1) - r(n), n = 1, 2, \dots, n-1 \quad (5.3)$$

onde  $r(i)$  é o tempo do ponto R.

O pedaço de código 5.3 usa a função apresentada em 5.3.

Listing 5.3: Algoritmo para extração do HRV.

```
for i = 1 : length(teo)
    if (teo(i)==0) continue;
    else count++;
    endif
    if (count == 1)
        a = i;
    elseif (count == 2)
        rr(1) = i - a;
        l++;
        count=0;
    endif
endfor
```

O EDR é uma técnica de processamento de sinal para derivar a respiração de um electrocardiograma. A área da onda R foi usada para extrair o sinal EDR do sinal ECG. Este cálculo é representado no código 5.4.

Listing 5.4: Algoritmo para extração do EDR

```
for i = 1 : length(w)
    if (i>length(teo_algorithm)) break
    endif
    if (i==1) continue;
```

## Classification Models for Sleep Apnea Detection and/or Prediction

Tabela 5.1: Time-Domain Measure For HRV(m) Epoch Sequence

RR(m)	$RR(m) = [rr_i]_{i=1}^m$	Feature Count
Mean	$\mu = \frac{\sum rr_i}{m}$	1
Standard Deviation	$\sigma = \sqrt{\frac{\sum (rr_i - \mu)^2}{m}}$	1
Sum of beats with interbeat difference over 50ms, variant 1	$NN50v1 = \sum_{i=2}^m \text{unit}( rr_i - rr_{i-1}  - 50ms)$	1
Sum of beats with interbeat difference over 50ms, variant 2	$NN50v2 = \sum_{i=1}^{m-1} \text{unit}( rr_{i+1} - rr_i  - 50ms)$	1
Ratio of NN50v1 to segment length	$pNN50v1 = \frac{NN50v1}{m}$	1
Ratio of NN50v2 to segment length	$pNN50v2 = \frac{NN50v2}{m}$	1
Mean of interbeat differentials	$\mu_{rd} = \frac{\sum rd_i}{m}$ , where $rd_i = rr_{i+1} - rr_i$	1
Standard deviation of interbeat differentials	$\sigma = \sqrt{\frac{\sum (rd_i - \mu_{rd})^2}{m}}$	1
Root mean square of interbeat differentials	$RMSSD = \sqrt{\frac{\sum rd_i^2}{m}}$	1
Serial correlation coefficients (k=1,...,5)	$r_k = \frac{\sum_{i=1}^{m-k} (rr_i - \mu_{rd})(rr_{i+k} - \mu_{rd})}{\sum_{i=1}^{m-k} (rr_i - \mu_{rd})^2}$	5
Fractal Alan Factors (k=5,10,15)	$AT_k = \frac{\sum (N_{i+1}[k] - N_i[k])^2}{2 * \sum N_{i+1}[k]}$ , $N_i[k]$ is the number of beats in the $i$ -th window of $k$ seconds	3
NEP (Number of Extreme Points)	$NEP = \frac{1}{m-2} \sum_{i=2}^{m-1} (1 - \text{unit}((rr_i - rr_{i-1})(rr_{i+1} - rr_i)))$	1

Tabela 5.2: Time-Domain Measure For EDR(q) Epoch Sequence

EDR(q)	$EDR(q) = [edr_i]_{i=1}^q$	Feature Count
Mean	$\mu_{edr} = \frac{\sum edr_i}{q}$	1
Standard Deviation	$\sigma_{edr} = \sqrt{\frac{\sum (edr_i - \mu_{edr})^2}{q}}$	1

```

endif
if (teo_algorithm(i) != 0)
    for j = (i-10) : i
        if (j > length(teo_algorithm) | j < 1) break;
        endif
        if (w(j) < max_value1)
            max_value1 = w(j);
            min1 = j;
        endif
    endfor
    for j = i : (i+10)
        if (j > length(w)) break
        endif
        if (w(j) < max_value2)
            max_value2 = w(j);
            min2 = j;
        endif
    endfor
    area_R(1) = trapz(w(min1:min2)) - trapz([min1 min2], [w(min1) w(min2)]);
    l++;
    max_value1 = intmax('int16');
    max_value2 = intmax('int16');
endif
endif

```

Como a classificação da base de dados foi providenciada para segmentos de 1 minuto, as características extraídas foram feitas nestes segmentos. Um total de 84 características foram extraídas, 34 do EDR e 50 do HRV. O PSD/FFT de 256 pontos foi calculado, sendo que foram retidos 64 pontos e apenas os primeiros 32 foram usados como características devido à simetria entre os pontos superiores e inferiores do PSD.

Tabela 5.3: Spectral-Domain measures for HRV and EDR epoch sequences

Spectral-Domain Measure	Feature Count
PSD/FFT Points	64

## 5.5 Selecção de características

"Feature Selection" ou Selecção de Características é um método importante para decidir que características usar e decidir como combinar essas características. O seu objectivo principal é seleccionar as mais relevantes e eliminar as irrelevantes [20].

Os benefícios desta técnica são melhorar a visualização dos dados, melhorar o conhecimento relativo à extração dos dados, reduzir o tempo e custo de treino [20]. A selecção de características em aprendizagem de máquina permite escolher um conjunto de características que atingem um erro baixo de acordo com uma certa perda. A selecção de características pode ser abordada usando métodos como filtros ou *wrappers*. Os filtros usam uma medida indirecta da qualidade das características seleccionadas para correlacionar as características escolhidas. Por outro lado, os *wrappers* usam a "qualidade de ajuste" entre input e output de acordo com um método de aprendizagem e minimizam o erro. Uma melhor escolha para medir a qualidade de um classificador é a área debaixo da curva (conhecida como AUC) da curva ROC (Receiver Operating Cover).

Uma curva ROC é um gráfico entre a fracção de verdadeiros positivos vs a fracção de falsos positivos para um sistema binário, assim o *threshold* discriminante é alterado [21]. A área debaixo da curva ROC, *AUC*, é uma medida global da performance de um modelo. Do ponto de vista probabilístico, se  $O_1$  e  $O_2$  são duas variáveis aleatórias representando os valores de output das duas classes  $C_1$  e  $C_2$ , respectivamente, pode ser provado que o *AUC* da "verdadeira" curva ROC é apenas  $AUC_{TRUE} = P(O_1 > O_2)$ , ou a probabilidade de quando duas amostras da Classe 1 e da Classe 2 são retiradas aleatoriamente de um output escolhido a primeira amostra  $O_1$  será maior que a segunda amostra  $O_2$ .

Este facto indica que a *AUC* pode ser usada como uma medida sustentada para a precisão global de uma classificação. A máxima precisão corresponde a um valor de 1 que significa a correcta separação de cada amostra independentemente do *threshold*; e o valor mínimo é de 0.5 que significa uma separação aleatória. Neste estudo, foi aplicado uma abordagem inovadora do uso da *AUC* para ordenar as características e seleccioná-las.

Para ordenar as características, de acordo com um "rank", e para proceder à selecção de características foi usado a *Discriminant Relevance (DR)* [20]. A DR é definida como a diferença entre o poder discriminatório de um modelo usando todas as variáveis e o modelo com todas as variáveis mas rejeitando a variável em estudo. Matematicamente falando, DR é definido como:

$$DR_i = \frac{AUC_0 - AUC_i}{AUC_0 - \frac{1}{2}} \quad (5.4)$$

onde  $AUC_0$  é o modelo AUC com todas as variáveis e  $AUC_i$  é o modelo AUC com todas as variáveis mas sem aquela em estudo.

Este método é importante porque pode determinar a importância de uma variável. Por exemplo, se  $DR \geq 1$ , o modelo necessita claramente da variável porque a ausência da variável leva a uma falta de poder discriminatório no sistema; caso contrário se  $DR \leq 0$  o efeito da variável é confuso e quando rejeitado, a performance do modelo será melhorada.

Juntamente com a importância, a significância do contributo para a classificação. A variável é apenas significativa se  $\Delta AUC$  não poder ser explicada devido a uma amostra finita. A hipótese de teste  $H_0$  é proposta para compara com a igualdade de *AUCs* com a hipótese alternativa da diferença positiva:

$$\left. \begin{array}{l} H_0 : AUC_i = AUC_0 \\ H_1 : AUC_i < AUC_0 \end{array} \right\} \quad (5.5)$$

onde  $H_0$  é a hipótese nula e  $H_1$  é hipótese alternativa. O propósito deste método é rejeitar a hipótese  $H_0$  quando a variável fizer um contributo significativo para o modelo [20].

Um teste estatístico para compara os dois modelos  $AUC$  é definido em baixo [22]:

$$z = \frac{AUC_0 - AUC_i}{\sqrt{SE_0^2 + SE_i^2 + 2pSE_0SE_i}} \quad (5.6)$$

onde  $SE_0$  é o erro *standard* de  $AUC_0$  e  $SE_i$  é o erro *standard* para  $AUC_i$ , e  $p$  é a correlação entre o  $AUC_0$  e  $AUC_i$ .

Depois a variável  $z$  foi usada como a importância final da característica, em percentagem. Assim, para seleccionar os diferentes conjuntos de características, iterou-se removendo as variáveis com  $z$  (importância) inferior a um *threshold*.

## 5.6 Classificação

Para classificar as características extraídas, 17401 registos foram anotados com 0 ou 1 no caso de um momento de apneia ou normal, respectivamente (46.33% de momentos de apneia e 53.67% de momentos normais). Estes dados foram divididos em 3 vectores: treino, teste e validação de forma aleatória. O método k-fold cross validation foi usado, com k=10, de forma a melhorar o treino dos classificadores. Para comparação com outros estudos e para gerar diferentes medidas de avaliação, a sensibilidade, especificidade e precisão foram calculadas para os diferentes classificadores. Estas métricas foram definidas como:

$$sensibilidade = \frac{TP}{TP + FN} \quad (5.7)$$

$$especificidade = \frac{TN}{TN + FP} \quad (5.8)$$

$$preciso = \frac{TP + TN}{P + N} \quad (5.9)$$

onde  $TP$  (True Positive) e  $TN$  (True Negative) refere ao número correcto de deteções de momentos de apneia e momentos normais, respectivamente, onde  $FP$  (False Positive) e  $FN$  (False Negative) refere-se ao número de momentos de apneia e normais mal classificados, respectivamente.  $P$  (Positive) e  $N$  (Negative) representa o total de momentos com e sem apneia, respectivamente. Noutras palavras, a sensibilidade reflecte a habilidade de detetar correctamente os momentos de apneia, especificidade é a habilidade de distinguir os momentos normais e precisão refere à correcta detecção de momentos de apneia e momentos normais.

Na fase de classificação, nove classificadores (ANN, SVM, LDA, PLS, REG, WienerHopf, aNBC, PLA and LMS) foram implementados para comparar a performance entre eles. Primeiro, uma rede neuronal foi implementada (Figure 5.1 mostra um exemplo de uma arquitectura de uma rede neuronal). Apenas NN

## Classification Models for Sleep Apnea Detection and/or Prediction

e SVM foram configurados com parâmetros diferentes dos pré-definidos para tentar chegar a um melhor propósito e os outros algoritmos foram usados com os valores pré-definidos.




Figura 5.1: A standard multi-layer ANN structure with l layers of units

### 5.6.1 Rede Neuronal

A rede neuronal implementada neste projecto foi configurada com 84 neurónios de input correspondente às características extraídas). Primeiro, os inputs são normalizados. Depois, são calculados o máximo e o mínimo de cada *input*. A função de activação usada foi a *tansig* e a *purelin* como função de transferência entre a camada de inputs e a camada interior e a entre a camada interior e a de output, respectivamente. A função *tansig* foi definida como:

$$tansig(n) = \frac{2}{1 + e^{-2n}} - 1$$

e a *purelin* é definida como:

$$purelin(n) = n$$

### 5.6.2 Support Vector Machine (SVM)

O SVM implementado foi desenvolvido com diferentes parâmetros C e com *Radial Basis Function (RBF)* como *kernel*. Um SVM *standard* tenta encontrar uma margem que separa todos os exemplos negativos e positivos. No entanto, isto pode levar a um mau design de classificadores se algum exemplo for mal anotado ou incomum. Para lidar com isto, em 1995, Cortes e Vapnik [CV95b] propuseram a ideia de uma 'soft margin' SVM que permite que alguns exemplos sejam 'ignorados' ou colocados no lado errado da margem; esta inovação leva a uma melhor *fit*. C é o parâmetro para esta margem, controlando a influência de cada support vector; este processo envolve troca de *error penalty* para estabilidade. O melhor resultado foi obtido com um C igual a 512.

## 5.7 Resultados

Para verificar a performance do sistema proposto nesta dissertação, 2 experiências computacionais foram executadas usando diferentes classificadores. Primeiro, 84 características foram usadas para treinar e simular o sistema e, de seguida, procedeu-se à seleção de características para obter as melhores características para classificar o problema inicial. Os dados passados para os classificadores foram divididos em dados de treino e teste seguindo a metodologia *k-fold cross validation* com k=10.

As experiências dividiram-se em duas partes: extração e classificação de características; selecção de características e classificação das mesmas. Foi inicialmente extraído e classificado 84 características que levaram

## Classification Models for Sleep Apnea Detection and/or Prediction

ao melhor resultado em termos de precisão de 63% pelo PLS; a melhor especificidade foi de 99.23% pelo SVM; e a melhor sensibilidade foi de 68.36% pelo PLA.

De seguida, quando a seleção de características foi aplicada, como explicado em 5.6, classificou-se diferentes conjuntos de características, organizados pelo "rank" dos mesmos, calculado pela *Discriminant Relevance*. Todas as características foram classificadas pelos mesmos classificadores.

As tabelas 5.4 e 5.5 apresentam todos os testes e os resultados alcançados. Todos os resultados foram importantes para compreender a evolução da classificação à medida que se remove as características. Para esta base de dados, é notado que a sensibilidade é, na maior parte dos casos, alta. Isto significa que os algoritmos conseguem detectar correctamente, na maior parte dos casos, momentos de apneia. No entanto, todos eles têm dificuldades em detetar correctamente todos os momentos normais. Aqui, a sensibilidade é uma constante, que a certo ponto, é benéfico pois permite a correcta deteção de todos os momentos de apneia.

O melhor resultado alcançado foi de 82.12% de precisão pela rede neuronal com 20 características. Estas características podem ser vistas como as características que mais se correlacionam entre si para detectar apneia de sono e momentos normais. A melhor sensibilidade foi de 100%, no entanto, neste caso, a especificidade foi de 0%, com 2 características apenas. A precisão, neste caso, foi de 62.24% devido à falha na especificidade. A melhor especificidade foi de 96.88% pelo LDA, porque tem poucas detecções de momentos de apneia. Quando a especificidade aumenta, a tendência é para que os momentos de apneia diminuam, assim como a precisão (Por exemplo, com 14 características, o LDA teve 96.88% de especificidade mas a sensibilidade foi de 3.31%).

Os diferentes gráficos permite visualizar a evolução da classificação através das características e comparar a performance com os diferentes algoritmos de classificação.

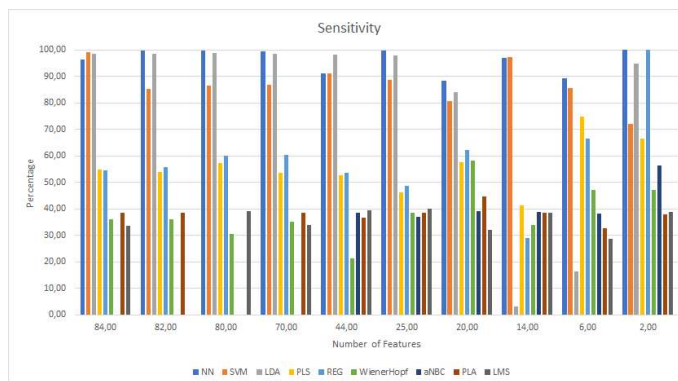


Figura 5.2: Comparação dos resultados da sensibilidade.




Figura 5.3: Comparação dos resultados da especificidade.

## Classification Models for Sleep Apnea Detection and/or Prediction

Tabela 5.4: Resultados para os diferentes conjuntos de características com comparação entre classificadores.

Número de características	Classificadores	Precisão	Sensibilidade	Especificidade
84	NN	59.40%	96.43%	2.67%
	SVM	61.61%	<b>99.23%</b>	0.87%
	LDA	60.57%	98.56%	0.95%
	PLS	<b>63.00%</b>	54.93%	65.24%
	REG	62.14%	54.66%	64.59%
	WienerHopf	58.43 %	36.21%	61.06%
	aNBC	62.12%	0%	62.12%
	PLA	40.91%	38.64%	<b>68.36%</b>
LMS	56.92%	33.53%	60.96%	
82	NN	61.98%	<b>99.75%</b>	0.37%
	SVM	<b>74.46%</b>	85.29%	56.52%
	LDA	61.19%	98.66%	0.92%
	PLS	63.88%	53.99%	<b>66.93%</b>
	REG	64.00%	55.78%	66.37%
	WienerHopf	60.15%	36.14%	62.16%
	aNBC	61.28%	0%	61.28%
	PLA	42.12%	38.62%	66.21%
LMS	61.01%	0%	61.01%	
80	NN	61.82%	<b>99.94%</b>	0.10%
	SVM	<b>74.09%</b>	86.53%	54.12%
	LDA	62.61%	98.88%	0.86%
	PLS	63.90%	57.26%	65.79%
	REG	64.70%	60.16%	65.71%
	WienerHopf	53.51%	30.69%	59.59%
	aNBC	61.47%	0%	61.47%
	PLA	61.33%	0%	61.33%
LMS	43.59%	39.11%	<b>65.83%</b>	
70	NN	62.17%	<b>99.58%</b>	0.74%
	SVM	<b>75.18%</b>	86.79%	56.45%
	LDA	61.01%	98.57%	0.64%
	PLS	62.89%	53.72%	65.66%
	REG	64.65%	60.35%	<b>65.75%</b>
	WienerHopf	59.29%	35.16%	61.76%
	aNBC	60.91%	0%	60.91%
	PLA	45.72%	38.57%	59.86%
LMS	59.87%	33.98%	61.36%	
44	NN	66.01%	91.17%	9.41%
	SVM	<b>70.00%</b>	91.33%	34.88%
	LDA	61.17%	<b>98.44%</b>	0.87%
	PLS	62.40%	52.64%	64.03%
	REG	62.24%	53.67%	63.39%
	WienerHopf	49.48%	21.33%	57.43%
	aNBC	38.86%	38.43%	<b>66.00%</b>
	PLA	61.36%	36.84%	61.70%
LMS	57.06%	39.64%	61.23%	
25	NN	62.348%	<b>99.97%</b>	0%
	SVM	<b>70.84%</b>	88.70%	41.78%
	LDA	61.58%	97.92%	1.17%
	PLS	61.28%	46.12%	63.26%
	REG	61.28%	48.74%	62.85%
	WienerHopf	61.15%	38.56%	62.13%
	aNBC	37.67%	37.14%	<b>65.71%</b>
	PLA	48.19%	38.57%	61.56%
LMS	51.47%	39.99%	62.00%	

## Classification Models for Sleep Apnea Detection and/or Prediction

Tabela 5.5: Resultados para os diferentes conjuntos de características com comparação entre classificadores

Número de características	Classificadores	Precisão	Sensibilidade	Especificidade
20	NN	<b>82.12%</b>	88.41%	72.29%
	SVM	70.94%	80.87%	54.94%
	LDA	62.93%	<b>83.98%</b>	28.40%
	PLS	64.49%	57.78%	66.05%
	REG	65.13%	62.23%	65.65%
	WienerHopf	64.05%	58.14%	65.27%
	aNBC	41.20%	39.24%	<b>79.21%</b>
	PLA	56.74%	44.58%	66.40%
	LMS	44.72%	32.09%	58.46%
14	NN	60.89%	97.13%	2.21%
	SVM	<b>62.68%</b>	<b>97.32%</b>	5.63%
	LDA	39.62%	3.31%	<b>96.88%</b>
	PLS	61.21%	41.38%	61.31%
	REG	60.99%	29.09%	61.24%
	WienerHopf	60.12%	33.98%	61.89%
	aNBC	39.37%	38.97%	64.44%
	PLA	38.53%	38.53%	0%
	LMS	59.17%	38.44%	61.86%
6	NN	59.80%	<b>89.40%</b>	11.15%
	SVM	<b>65.92%</b>	85.59%	34.37%
	LDA	42.33%	16.46%	<b>83.65%</b>
	PLS	61.75%	75%	61.74%
	REG	60.73%	66.67%	60.73%
	WienerHopf	61.65%	47.21%	62.26%
	aNBC	38.95%	38.26%	67.15%
	PLA	59.03%	32.57%	60.75%
	LMS	61.72%	28.70%	62.35%
2	NN	62.24%	<b>100%</b>	0%
	SVM	<b>64.00%</b>	72.15%	50.87%
	LDA	61.43%	94.77%	7.46%
	PLS	61.92%	66.67%	61.92%
	REG	61.51%	<b>100%</b>	61.49%
	WienerHopf	60.56%	47.25%	61.32%
	aNBC	62.07%	56.40%	62.71%
	PLA	39.55%	38.08%	56.16%
	LMS	39.27%	38.75%	<b>71.43%</b>

## Classification Models for Sleep Apnea Detection and/or Prediction

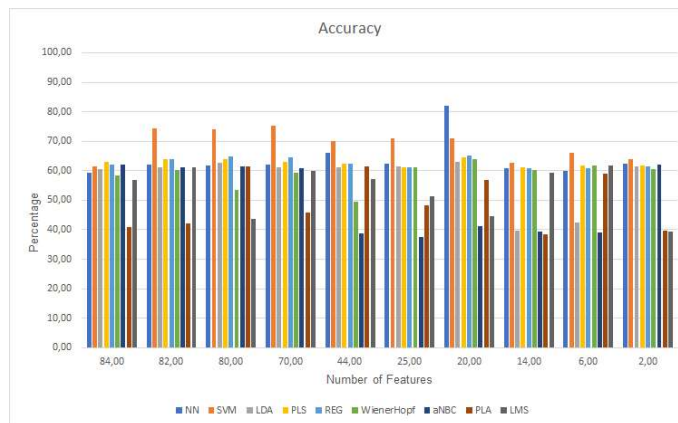


Figura 5.4: Comparação dos resultados da precisão.

## 5.8 Discussão

Analisando os resultados apresentados na seção anterior, os diferentes classificadores apresentados apresentam diferentes comportamentos, dependendo no número de características dadas para classificação. Por exemplo, com 70 características foi obtido uma precisão de 75.18% pelo SVM e com a sensibilidade de 86.79% e especificidade de 56.45%. No entanto, com 44 características foi alcançado uma precisão de 70.00% pelo SVM, mas a sensibilidade é de 91.33% e a especificidade de 34.88%. Aqui, como pode ser visualizado, diferentes características obtêm diferentes precisões, sensibilidades e especificidades.

Foi observado que o melhor classificador foi a ANN com 20 características. Assim, estas características, juntas, são mais correlacionadas e trazem mais informação à solução do problema dentro de todas as características extraídas. Além disso, foi claramente visível que diferentes classificadores têm diferentes resultados na sensibilidade e especificidade também.

Os resultados apresentados são comparáveis com outros estudos que usaram a mesma base de dados (PhysioNet ECG-Apnea). Isto é importante para compreender e validar os métodos usados neste estudo e nos outros estudos também. Num estudo de comparação de performance de diferentes classificadores, o melhor classificador foi o Bagging.REPTree com uma precisão de 84.4% e uma especificidade de 85.9%. A melhor sensibilidade foi o AdaBoost com um total de 87.03% [XM].

Noutro estudo, [VTB<sup>+</sup>] extrai apenas 4 características e obteve uma sensibilidade de 72.47% com o AdaBoost, uma especificidade de 83.29% e uma precisão de 85.07%.

Noutro estudo que usaram o ELM [SC], os resultados alcançados foram: precisão de 87.71%, especificidade de 91.7% e sensibilidade de 81.3%. Apesar dos bons resultados, a sensibilidade é pequena comparada com outros estudos. É importante garantir que todos os momentos de apneia de sono sejam corretamente detetados. Se um momento normal é mal classificado ele pode ser corrigido e não se torna um problema muito grave. No entanto, um momento de apneia mal-classificado é um problema. Assim, sensibilidade é mais importante que a especificidade.

Numa monitorização em tempo real [BMT], bons resultados foram alcançados com a sensibilidade de 96%; no entanto o PSG foi usado como suporte no estudo.

Finalmente, em [CHS<sup>+</sup>], 2 classificadores foram desenvolvidos para resolver este problema. *Linear Discriminant* (LD) e *Quadratic Discriminant* (QD). Estes classificadores foram testados usando 3 diferentes métodos, incluindo optimização, selecção de características e regularização de co-variância. Os resultados foram interessantes. Sem optimização, QD atingiu a melhor especificidade, 94.6% e LD atingiu a melhor sensibilidade (94%). A melhor precisão, como esperado, foi atingida com selecção de características (93.2% com o QD). No entanto, o teste sem optimização atingiu melhor sensibilidade.

O sistema proposto obtém uma precisão de 82.12%, especificidade de 72.29%, e sensibilidade de 88.41%.

Nas experiências realizadas o rácio sensibilidade/especificidade é alto, o que significa que a detecção dos momentos, tanto de apneia como normais, sejam precisos. Esta sensibilidade alta suporta a abordagem neste estudo. Apesar disto, uma comparação entre diferentes classificadores foi conduzida para consolidar os objectivos atingidos. Diferentes classificadores têm diferentes comportamentos. Assim, quando é apresentado uma solução para o problema, um classificador deve ser comparado com outros para determinar qual o melhor para a solução do problema porque têm diferentes comportamentos sobre os dados.

As características foram colocadas num "rank" e classificadas de acordo com esta importância e o comportamento destas nos diferentes classificadores foram apresentadas. A selecção de características é importante para determinar qual o papel/importância de cada característica extraída.

### 5.9 Conclusão

Este estudo apresenta um modelo para detecção de apneia de sono baseado no ECG. O objectivo principal foi apresentar um método alternativo ao PSG para classificar a apneia de sono, e/ou, perceber a importância das características do estado da arte. Cada conjunto de características, baseado no "rank", foi classificado e comparado com a precisão dos diferentes classificadores.

De acordo com os resultados obtidos, podemos concluir que diferentes características têm uma importância diferente no sistema de diagnóstica, e como consequência, diferentes classificadores têm diferentes comportamentos na resolução do problema quando apresentado com diferentes características.

Adicionalmente, como evidenciado nas nossas experiências, uma selecção de características adequadas poderá levar a um aumento da precisão. Assim, o sistema proposto evidenciou que é apto, viável e preciso para a detecção de apneia de sono usando o sinal ECG. Neste estudo, uma precisão de 82.12%, com uma sensibilidade de 88.41% e uma especificidade de 72.29% foi obtida através da rede neuronal com 20 características. Todas as características foram extraídas baseando-se na literatura não são as melhores para a solução do problema porque nem todas trazem conhecimento para o classificador para uma melhor performance.

# Capítulo 6

## Conclusões e Trabalho Futuro

No âmbito desta dissertação, foi possível avançar e adicionar os conhecimentos principais sobre machine learning e ao mesmo tempo estudá-los para aplicação em situações reais, neste caso, uma situação clínica. Este capítulo contém as seguintes secções:

- secção 6.1 – **Conclusões Principais** – apresenta detalhadamente as conclusões retiradas da realização do estudo.
- secção 6.2 – **Trabalho futuro** – apresenta detalhadamente o trabalho que irá ser feito no futuro como complemento ao trabalho já realizado.

### 6.1 Conclusões Principais

Este estudo apresenta um modelo para análise e detecção de apneia de sono num ECG. O objectivo principal foi apresentar várias possibilidades de algoritmos para detecção e perceber que tipo de características mais se adequam à classificação e detecção da apneia de sono num ECG, que é, uma alternativa ao clássico PSG. Cada conjunto de características, baseadas no ranking, foram classificadas para comparar a precisão dos diferentes classificadores.

De acordo com os resultados obtidos, podemos concluir que diferentes características produzem diferentes comportamentos no sistema e, como consequência, diferentes classificadores têm também diferentes comportamentos na solução deste problema.

Adicionalmente, como já evidenciado, uma adequada selecção de características podem levar a um aumento da precisão dos classificadores. Assim, o sistema proposto evidencia a sua aptidão, viabilidade e precisão na detecção de apneia de sono usando um sinal ECG. Neste estudo, uma precisão de 82.12%, com uma sensibilidade de 88.41% e uma especificidade de 72.29% foram obtidas pela ANN com 20 características. Todas as características foram extraídas baseadas na literatura não são as ideais para a solução do problema porque nem todas trazem novo conhecimento para os classificadores aumentarem a sua performance.

Como complemento ao estudo efetuado, dois papers foram produzidos para revista e estão em processo de aceitação. Os papers são intitulados Towards an Accurate Sleep Apnea Detection Based on ECG Signal: The Quintessential of a Wise Feature Selection e Classifier Precision Analysis for Sleep Apnea Detection with ECG Signals.

### 6.2 Trabalho futuro

O trabalho futuro pode incluir melhorar a sensibilidade do sistema para que todos os momentos de apneia sejam correctamente detectados; e comparar e calcular a performance computacional dos diferentes métodos aplicados neste estudo, incluindo avaliação do custo computacional do pré-processamento do sinal, extração de características e performance dos classificadores.

Finalmente, estudos complementares devem ser adicionados para elevar a performance dos classificadores do sistema proposto e usar diferentes características e/ou métodos.

## **Classification Models for Sleep Apnea Detection and/or Prediction**

## Bibliografia

- [20] Feature selection using ROC curves on classification problems. Available from: [https://www.researchgate.net/publication/221533549\\_Feature\\_selection\\_using\\_ROC\\_curves\\_on\\_classification\\_problems](https://www.researchgate.net/publication/221533549_Feature_selection_using_ROC_curves_on_classification_problems). 27, 28
- [21] Introduction to ROC analysis. Available from: [https://www.researchgate.net/publication/222511520\\_Introduction\\_to\\_ROC\\_analysis](https://www.researchgate.net/publication/222511520_Introduction_to_ROC_analysis). 27
- [22] A Method of Comparing the Areas Under Receiver Operating Characteristic Curves Derived from the Same Cases. Available from: [https://www.researchgate.net/publication/16319730\\_A\\_Method\\_of\\_Comparing\\_the\\_Areas\\_Under\\_Receiver\\_Operating\\_Characteristic\\_Curves\\_Derived\\_from\\_the\\_Same\\_Cases](https://www.researchgate.net/publication/16319730_A_Method_of_Comparing_the_Areas_Under_Receiver_Operating_Characteristic_Curves_Derived_from_the_Same_Cases). 28
- [AaKKP08] T. Al-ani, C. K. Karmakar, A. H. Khandoker, and M. Palaniswami. Automatic recognition of obstructive sleep apnoea syndrome using power spectral analysis of and hidden markov models. In *2008 International Conference on Intelligent Sensors, Sensor Networks and Information Processing*, pages 285–290, Dec 2008. 1
- [AB13] Cafer Avci and Gokhan Bilgin. Sleep apnea detection using adaptive neuro fuzzy inference system. Junho 2013. Available from: [http://file.scirp.org/pdf/ENG\\_2013103114153977.pdf](http://file.scirp.org/pdf/ENG_2013103114153977.pdf). 9
- [AEFA13] Laiali Almazaydeh, Khaled Elleithy, Miad Faezipour, and Ahmad Abushakra. Apnea Detection based on Respiratory Signal Classification. *Procedia Computer Science*, 21:310–316, January 2013. Available from: <http://www.sciencedirect.com/science/article/pii/S187705091300834X>. 1
- [BMT] M. Bsoul, H. Minn, and L. Tamil. Apnea MedAssist: Real-time sleep apnea monitor using single-lead ECG. volume 15, pages 416–427. 33
- [BMT11] Majdi Bsoul, Hlaing Minn, and Lakshamn Tamil. Apnea medassist: Real-time sleep apnea monitor using single-lead ecg. Maio 2011. Available from: <http://www.utdallas.edu/~hxm025000/MajdiTITB2011May.pdf>. 10
- [CHS<sup>+</sup>] P. de Chazal, C. Heneghan, E. Sheridan, R. Reilly, P. Nolan, and M. O’Malley. Automated processing of the single-lead electrocardiogram for the detection of obstructive sleep apnoea. volume 50, pages 686–696. 33
- [CV95a] Corinna Cortes and Vladimir Vapnik. Support-Vector Networks. *Machine Learning*, 20(3):273–297, September 1995. Available from: <http://link.springer.com/article/10.1023/A:1022627411411>. 16
- [CV95b] Corinna Cortes and Vladimir Vapnik. Support-vector networks. volume 20, pages 273–297. 1995. Available from: <http://dx.doi.org/10.1023/A:1022627411411>. 29
- [dCHS<sup>+</sup>03] Philip de Chazal, Conor Heneghan, Elaine Sheridan, Richard Reilly, Philip Nolan, and Mark O’Malley. Automated processing of the single-lead electrocardiogram for the detection of obstructive sleep apnoea. Junho 2003. Available from: <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=1203807>. 11

## Classification Models for Sleep Apnea Detection and/or Prediction

- [GSF14] Huseyin Guruler, Mesut Sahin, and Abdullah Ferikoglu. Feature selection on single-lead ecg for obstructive sleep apnea diagnosis. Janeiro 2014. Available from: [https://www.researchgate.net/publication/256436452\\_Feature\\_selection\\_on\\_single-lead\\_ECG\\_for\\_obstructive\\_sleep\\_apnea\\_diagnosis](https://www.researchgate.net/publication/256436452_Feature_selection_on_single-lead_ECG_for_obstructive_sleep_apnea_diagnosis). 8
- [HS11] Chien-Chang Hsu and Ping-Ta Shih. A novel sleep apnea detection system in electroencephalogram using frequency variation. *Expert Systems with Applications*, 38(5):6014 – 6024, 2011. Available from: [//www.sciencedirect.com/science/article/pii/S095741741001256X](http://www.sciencedirect.com/science/article/pii/S095741741001256X). 1
- [HSW89] Kurt Hornik, Maxwell Stinchcombe, and Halbert White. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5):359–366, 1989. Available from: <http://www.sciencedirect.com/science/article/pii/0893608089900208>. 15
- [KGH<sup>+</sup>14] Tetyana Kendzerska, Andrea S. Gershon, Gillian Hawker, Richard S. Leung, and George Tomlinson. Obstructive sleep apnea and risk of cardiovascular events and all-cause mortality: A decade-long historical cohort study. volume 11, pages 1–15. Public Library of Science, 02 2014. Available from: <https://doi.org/10.1371/journal.pmed.1001599>. 1
- [KGP08] AH Khandoker, J. Gubbi, and M. Palaniswami. Recognizing central and obstructive sleep apnea events from normal breathing events in ecg recordings. Setembro 2008. Available from: [http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4749133&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs\\_all.jsp%3Farnumber%3D4749133](http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4749133&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D4749133). 13
- [KSKS96] Ben Krose, Patrick Van Der Smagt, Ben Krose, and Patrick Van Der Smagt. *An introduction to Neural Networks*. 1996. 15
- [MF00] J.N. McNames and A.M. Fraser. Obstructive sleep apnea classification based on spectrogram patterns in the electrocardiogram. pages 749–752. IEEE, 2000. Available from: <http://ieeexplore.ieee.org/document/898633/>. 19
- [OLA<sup>+</sup>16] Ike S. Okwuosa, Sabra C. Lewsey, Tolulope Adesiyun, Roger S. Blumenthal, and Clyde W. Yancy. Worldwide disparities in cardiovascular disease: Challenges and solutions. volume 202, pages 433–440. Elsevier Ireland Ltd, 1 2016. 1
- [OPH<sup>+</sup>16] Kentaro Okuno, Benjamin T. Pliska, Mona Hamoda, Alan A. Lowe, and Fernanda R. Almeida. Prediction of oral appliance treatment outcomes in obstructive sleep apnea: A systematic review. volume 30, pages 25 – 33. 2016. Available from: <http://www.sciencedirect.com/science/article/pii/S1087079215001586>. 1, 6
- [PG16] N. Pombo and N. M. Garcia. ubisleep: An ubiquitous sensor system for sleep monitoring. In *2016 IEEE 12th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, pages 1–4, Oct 2016. 1
- [PGB17] Nuno Pombo, Nuno Garcia, and Kouamana Bousson. Classification techniques on computerized systems to predict and/or to detect apnea: A systematic review. *Computer Methods and Programs in Biomedicine*, 140:265 – 274, 2017. Available from: [//www.sciencedirect.com/science/article/pii/S0169260716306113](http://www.sciencedirect.com/science/article/pii/S0169260716306113). 1
- [PVT07] A. Patangay, P. Vemuri, and A. Tewfik. Monitoring of obstructive sleep apnea in heart failure patients. In *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 1043–1046, Aug 2007. 1

## Classification Models for Sleep Apnea Detection and/or Prediction

- [RRO<sup>+</sup>09a] Warren R Ruehland, Peter D Rochford, Fergal J O'Donoghue, Robert J Pierce, Parmjit Singh, and Andrew T Thornton. The New AASM Criteria for Scoring Hypopneas: Impact on the Apnea Hypopnea Index. volume 32, pages 150–157. February 2009. Available from: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC2635578/>. 1
- [RRO<sup>+</sup>09b] Warren R Ruehland, Peter D Rochford, Fergal J O'Donoghue, Robert J Pierce, Parmjit Singh, and Andrew T Thornton. The New AASM Criteria for Scoring Hypopneas: Impact on the Apnea Hypopnea Index. *Sleep*, 32(2):150–157, February 2009. Available from: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC2635578/>. 1
- [SC] N. Sadr and P. de Chazal. Automated detection of obstructive sleep apnoea by single-lead ECG through ELM classification. In *Computing in Cardiology 2014*, pages 909–912. 33
- [SdC14] Nadi Sadr and Philip de Chazal. Automated detection of obstructive sleep apnea by single-lead ecg through elm classification. Setembro 2014. Available from: [https://www.researchgate.net/publication/281650004\\_Automatic\\_Screening\\_of\\_Obstructive\\_Sleep\\_Apnea\\_from\\_Single-Lead\\_Electrocardiogram](https://www.researchgate.net/publication/281650004_Automatic_Screening_of_Obstructive_Sleep_Apnea_from_Single-Lead_Electrocardiogram). 14
- [SKN09] T. Sugi, F. Kawana, and M. Nakamura. Automatic EEG arousal detection for sleep apnea syndrome. *Biomedical Signal Processing and Control*, 4(4):329–337, October 2009. Available from: <https://www.sciencedirect.com/science/article/pii/S1746809409000494>. 1
- [SL] Leif Sörnmo and Pablo Laguna. Electrocardiogram (ECG) signal processing. In *Wiley Encyclopedia of Biomedical Engineering*. John Wiley & Sons, Inc. Available from: <http://onlinelibrary.wiley.com/doi/10.1002/9780471740360.ebs1482/abstract>. 18
- [SS15] Necmettin Sezgin and Necmettin Sezgin. EMG classification in obstructive sleep apnea syndrome and periodic limb movement syndrome patients by using wavelet packet transform and extreme learning machine. *Turkish Journal of Electrical Engineering and Computer Science*, 23(3):873–884, August 2015. Available from: <http://sdu.dergipark.gov.tr/tbtkelektrik/144851>. 1
- [SW15] Motoki Sakai and Daming Wei. Holter ecg-based apnea hypoapnea index to screen obstructive sleep apnea: A new proposal and evaluation of feasibility. Novembro 2015. Available from: [http://file.scirp.org/pdf/JBM\\_2015110614262847.pdf](http://file.scirp.org/pdf/JBM_2015110614262847.pdf). 10
- [VTB<sup>+</sup>] C. Varon, D. Testelmans, B. Buyse, J. A. K. Suykens, and S. Van Huffel. Sleep apnea classification using least-squares support vector machines on single lead ECG. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 5029–5032. 33
- [VTB<sup>+</sup>12] Carolina Varon, Dries Testelmans, Bertien Buyne, Johan A.K. Suykens, and Sabine Van Huffel. Robust artefact detection in long-term ecg recordings based on autocorrelation function similarity and percentile analysis. Janeiro 2012. Available from: <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6346633>. 14
- [VTB<sup>+</sup>13] Carolina Varon, Dries Testelmans, Bertien Buyse, Johan A.K. Suykens, and Sabine Van Huffel. Sleep apnea classification using least-squares support vector machines on single lead ecg. Outubro 2013. Available from: <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6610678>. 13

## Classification Models for Sleep Apnea Detection and/or Prediction

- [XM] B. Xie and H. Minn. Real-time sleep apnea detection by classifier combination. volume 16, pages 469–477. 33
- [XM12] Baile Xie and Hlaing Minn. Real-time sleep apnea detection by classifier combination. Maio 2012. Available from: <http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=6153377>. 8