

Faculdade de Engenharia da Universidade do Porto



Deteção de Extra-Sístoles Ventriculares

Aurélio Filipe de Sousa e Silva

Mestrado Integrado em Bioengenharia
Ramo - Engenharia Biomédica

Co-orientador: Dr. Ricardo Sousa
Orientador: Prof. Dr. Aníbal Ferreira

Porto, Julho de 2012

Deteção de Extra-Sístoles Ventriculares

Aurélio Filipe de Sousa e Silva

Mestrado Integrado em Bioengenharia
Ramo - Engenharia Biomédica

Aprovado em prova pública pelo Júri:

Presidente: Artur Cardoso (FEUP)

Vogal Externo: Guilherme Campos (Universidade de Aveiro)

Co-orientador: Ricardo Sousa (FEUP)

Orientador: Aníbal Ferreira (FEUP)

Em 23 de Julho de 2012.

Resumo

Este trabalho visa a aplicação de conceitos e metodologias de processamento de sinal eletrocardiográfico com o intuito de detetar uma anomalia específica nos batimentos cardíacos - as extra-sístoles ventriculares.

Inicialmente foram aplicadas técnicas de pré-processamento para remover componentes indesejados nos sinais, tais como oscilações de linha de base, componente DC e componentes de frequência superior ao limite máximo de interesse do sinal ECG (40 Hz). O passo seguinte incidiu na construção de um algoritmo detetor de picos Q,R e S de cada batimento cardíaco dos sinais ECG. A partir da localização dos picos R construiu-se um algoritmo simples de deteção de extra-sístoles ventriculares. Posteriormente, a partir das localizações dos 3 picos - Q, R e S - extraíram-se características dos batimentos cardíacos dos sinais, aplicaram-se métodos de redução da dimensão das mesmas e utilizaram-se dois algoritmos de classificação - *Support Vector Machines* e *Kth Nearest-Neighbors Rule* - para a deteção de extra-sístoles ventriculares. O desempenho dos algoritmos foi avaliado com recurso a alguns sinais da *MIT-BIH Arrhythmia Database*.

Os resultados obtidos revelaram um grande potencial do 1º algoritmo simples construído para deteção de extra-sístoles ventriculares. Como a lógica de deteção deste algoritmo se baseia apenas numa característica do sinal ECG, podem ser consideradas mais características criteriosamente selecionadas sem resultar num algoritmo complexo. Além disso, a inclusão de mais parâmetros poderá conduzir a um desempenho de deteção de extra-sístoles ventriculares que torne adequada a utilização deste algoritmo em ambientes hospitalares.

Palavras-chave: Processamento de Sinal Eletrocardiográfico (ECG), Deteção de Complexos QRS, Deteção de Extra-Sístoles Ventriculares (ESV), *Support Vector Machines*, *Kth Nearest-Neighbors Rule*, *MIT-BIH Arrhythmia Database*.

Abstract

The purpose of this work is the application of concepts and methodologies of electrocardiographic (ECG) signal processing in order to detect a specific abnormality in heartbeats - the ventricular extrasystoles or premature ventricular contractions (PVCs).

Initially, techniques of pre-processing were applied to remove undesired components of the signals, such as baseline drift, DC component and components with a frequency higher than the maximum value of frequency present in the ECG signal spectrum (40 Hz). The next step was the construction of an algorithm capable of detecting Q, R and S peaks of each heartbeat. Through the location of the R peaks, a simple algorithm for detecting PVCs was constructed. Further, through the location of the Q, R and S peaks, features from heartbeats were extracted, methods for reduction of its dimension were applied and two classifiers were used - Support Vector Machines and K^{th} Nearest-Neighbors Rule - for detecting PVCs. The performance of the algorithms was assessed using some ECGs of the MIT-BIH Arrhythmia Database.

The obtained results revealed a great potential of the first simple algorithm constructed for detecting PVCs. Since the detection logic of this algorithm is based only in a parameter of the ECG signal, more parameters can be strictly selected and included in the algorithm without making it complex. Furthermore, the inclusion of more parameters may lead to a performance that makes the algorithm useful in clinical environments.

Keywords: Electrocardiographic (ECG) Signal Processing, QRS Complex Detection, Premature Ventricular Contractions (PVC) Detection, Support Vector Machines, K^{th} Nearest-Neighbors Rule, MIT-BIH Arrhythmia Database.

Agradecimentos

Com os melhores agradecimentos ao Professor Doutor Aníbal Ferreira por tornar possível a realização deste trabalho e pelas orientações fornecidas ao longo do desenvolvimento do mesmo.

Um enorme agradecimento vai também para o Doutor Ricardo Sousa, que foi uma ajuda constante ao longo do desenvolvimento do trabalho.

Índice

Resumo	v
Abstract.....	vii
Agradecimentos	ix
Índice.....	xi
Lista de figuras	xiii
Lista de tabelas	xvii
Abreviaturas e Símbolos	xix
Capítulo 1	21
Introdução.....	21
Capítulo 2	23
Enquadramento Conceptual.....	23
2.1 - Introdução.....	23
2.2 - O sistema de condução do coração.....	23
2.3 - Potencial de ação e contração das fibras contrácteis.....	25
2.4 - Eletrocardiografia	28
2.5 - ECG de 12 Derivações	30
2.6 - Correlação das ondas ECG com as sístoles auricular e ventricular.....	32
2.7 - Arritmias Cardíacas.....	33
2.8 - Gravação de ECG em regime ambulatorio.....	34
2.9 - Definição de Extra-Sístole.....	36
2.10 - Extra-Sístoles Ventriculares	38
2.11 - Relevância Clínica das ESV.....	41
2.12 - Resumo	43
Capítulo 3	45
Reconhecimento de padrões em sinais ECG.....	45
3.1 - Introdução.....	45
3.2 - Remoção de ruído.....	45
3.3 - Detecção de complexos QRS	46
3.4 - Algoritmia de deteção e classificação	47
3.5 - Classificação não supervisionada	48
3.6 - Classificação supervisionada.....	51
3.7 - Resumo	55
Capítulo 4	57
Deteção automática de ESV.....	57
4.1 - Introdução.....	57
4.2 - Metodologia.....	57
4.2.1 - Base de dados	57
4.2.2 - Pré-processamento	59
4.2.3 - Detetor de complexos QRS	60

4.2.4 - Primeiro algoritmo detetor de ESV	69
4.2.5 - Extração e processamento de características	72
4.2.6 - Teste de parâmetros para os algoritmos de classificação	75
4.2.7 - Teste de características e classificação	78
4.3 - Resultados e discussão.....	78
4.3.1 - Detetor de complexos QRS.....	79
4.3.2 - Primeiro algoritmo detetor de ESV	80
4.3.3 - Extração e processamento de características	81
4.3.4 - Teste de parâmetros para os algoritmos de classificação	83
4.3.5 - Teste de características e classificação	84
4.4 - Resumo	89
Capítulo 5	91
Conclusões gerais e perspectivas futuras	91
Referências	93
Referências Bibliográficas.....	93
Referências Sitiográficas	95
ANEXOS	97
Anexo 1	99
Anexo 2	103

Lista de figuras

- Figura 1 - Sistema de condução de coração, indicando por meio de setas a direção de propagação dos potenciais de ação. Nota: os números da figura não coincidem com os números que representam as fases do ciclo de condução no texto. 1-Origem dos potenciais de ação no nó SA e sua propagação através da parede da aurícula até ao nó AV; 2-Propagação dos potenciais pelo nó AV e pelo feixe de His, que se estende desde o nó AV até ao septo interventricular; 3-Os potenciais de ação descem para o vértice de cada ventrículo através de cada um dos ramos do feixe de His; 4-Os potenciais de ação são transportados pelas fibras de Purkinje até às paredes ventriculares [2]. 25
- Figura 2 - Potenciais marca-passo e potenciais de ação nas fibras autorrítmicas do nó SA [1]. 25
- Figura 3 - Potencial de ação numa fibra contráctil. O potencial de repouso da membrana é de cerca de -90 mV [1]. 27
- Figura 4 - Eletrocardiograma normal. Onda P: despolarização auricular; Complexo QRS: início da despolarização ventricular; Onda T: repolarização ventricular [1]. 28
- Figura 5 - Derivações do plano frontal. (A) Triângulo de Einthoven formado pelas derivações I, II e III; (B) Derivações unipolares dos membros, aVR, aVL e aVF [3]. 31
- Figura 6 - Derivações do peito. (A) posicionamento dos elétrodos nos espaços intercostais; (B) Distribuição das derivações pelos diferentes espaços do coração [3]. 31
- Figura 7 - Caminho e *timing* das despolarizações e repolarizações ao longo do sistema de condução e miocárdio visíveis num ECG. Os traços a verde indicam despolarização e os traços vermelhos indicam repolarização [1]. 33
- Figura 8 - Espectro de frequências da onda P, complexo QRS e onda T do sinal ECG. As localizações dos diferentes componentes no espectro correspondem a uma aproximação um pouco grosseira, uma vez estas localizações variam consideravelmente de acordo com o indivíduo, derivação de sinal associada e origem do batimento cardíaco analisado (ex.: batimento normal, extra-sístole, etc.) [6]. 35
- Figura 9 - Representação de uma extra-sístole (seta vermelha) entre dois batimentos normais. Na figura está representada uma situação em que existe pausa compensatória: $Rs2Re + ReRs3 = Rs3Rs5$ (I). 36
- Figura 10 - Tipos de extra-sístoles. A - Extra-sístole interpolada; B - Extra-sístole prematura; C - Grupo de extra-sístoles (I). 37
- Figura 11 - Representação de uma ESV entre batimentos normais. Observa-se claramente que as ESV apresentam uma maior amplitude do pico R, uma maior largura do complexo QRS, uma onda T com polaridade invertida, e ausência de onda P precedente (IV). 38
- Figura 12 - Extra-sístoles ventriculares (ESV). Os registos de A a D foram gravados do mesmo paciente. (A) Uma ESV tardia resulta na presença de uma pausa compensatória; (B) Uma taxa sinusal mais lenta resulta numa excitação auricular retrógrada - P'; (C) Os eventos são similares aos de (B), mas em C ocorre uma batida de fusão - F - que é fruto de uma taxa sinusal ligeiramente mais alta; (D) O impulso

que se propaga retrogradamente para as aurículas reverte a sua direção após um atraso e retorna aos ventrículos, excitando-os. (E) A uma ESV interpolada segue-se um batimento que apresenta um intervalo P-R ligeiramente mais longo do que o normal. Os gráficos mostrados correspondem à derivação II do ECG. Os círculos vermelhos indicam a origem das ESV [7].....	39
Figura 13 - Padrões de ECG nos bloqueios de ramo. (A) Bloqueio de ramo direito: É visível a onda R elevada nas derivações III, V1 e V2 e a deflexão negativa da onda S nas derivações I, V5 e V6. É também visível a onda R elevada nas derivações V1 e V2 e a deflexão negativa da onda S nas derivações V5 e V6. (B) Bloqueio do ramo esquerdo: É visível a elevação da onda R nas derivações I, V5 e V6 e a deflexão negativa da onda S nas derivações III, V1 e V2 (I).	40
Figura 14 - Padrões temporais de ocorrência de ESV. (A) Bigeminismo; (B) Trigeminismo. As setas da figura indicam as ESV (I).	41
Figura 15 - Extra-sístoles ventriculares multiformes. Os complexos QRS extra-sistólicos “normais” para esta onda apresentam uma morfologia de bloqueio de ramo esquerdo (ponta de seta vermelha), e a estes complexos seguem-se outras ESV com diferentes morfologias. A derivação de sinal apresentada é a V1 [7].	41
Figura 16 - Estrutura de um detetor de complexos QRS [16].	46
Figura 17 - Agrupamento (<i>clustering</i>) de um ECG que contém duas diferentes morfologias de batimentos cardíacos - 7 batimentos normais e 2 batimentos ectópicos. Os dois batimentos ectópicos são duas ESV [6].....	50
Figura 18 - Batimentos cardíacos normais (à esquerda) e coeficientes <i>wavelet</i> (à direita) [25].	54
Figura 19 - Desempenho do classificador para os 6 tipos de classificação. N (normal e anormal), V (ESV e não ESV), A (ESA e não ESA). A representação consiste em diagramas de caixa, em que as linhas representam a média e os quartis superior e inferior. Os números à frente da letra indicam a dimensão do vetor de características utilizado na classificação [25].	54
Figura 20 - Algumas das morfologias de ESV presentes nos sinais. (A) ESV do sinal mit119; (B) ESV do sinal mit213; (C) ESV do sinal mit223; (D) ESV do sinal mit233. Todos os 4 ciclos cardíacos da figura estão aproximadamente à mesma escala.	58
Figura 21 - Teste de diferentes ordens para o filtro passa-alto. A ordem 1000 foi a mínima ordem que permitiu um alinhamento adequado do sinal no nível isoeletrico. Como o método de filtragem usado é a filtragem de fase 0, os filtros aplicados correspondem na realidade a uma ordem que é o dobro da ordem especificada na legenda. O sinal utilizado foi o sinal mit103 da <i>MIT-BIH Arrhythmia Database</i>	59
Figura 22 - Resposta em magnitude e em fase da combinação dos dois filtros. Saliente-se que esta representação corresponde às especificações dos dois filtros. Como a filtragem é de fase 0, a resposta em magnitude é o quadrado da resposta representada e a resposta de fase é uma linha reta em 0.....	60
Figura 23 - Diagrama de blocos do processamento de sinal intrínseco ao detetor de picos QRS.	60
Figura 24 - Resposta em magnitude e em fase da combinação do filtro-passa alto com $F_c = 5$ Hz e do filtro passa-baixo com $F_c = 15$ Hz.	62
Figura 25 - Resultado da operação de filtragem sequencial do sinal pré-processado com os filtros passa-baixo de 15 Hz e passa-alto de 5 Hz. O sinal filtrado representado	

encontra-se já com o atraso compensado. O sinal utilizado foi o sinal mit103 da <i>MIT-BIH Arrhythmia Database</i>	62
Figura 26 - Diferenciação do sinal filtrado. O sinal utilizado foi o sinal mit103 da <i>MIT-BIH Arrhythmia Database</i>	63
Figura 27 - Resultado da execução do quadrado da derivada do sinal. O sinal utilizado foi o sinal mit103 da <i>MIT-BIH Arrhythmia Database</i>	64
Figura 28 - Resultado da execução de uma média móvel de 72 pontos ao sinal resultante do passo anterior. O sinal resultante representado encontra-se já com o atraso compensado. O sinal utilizado foi o sinal mit103 da <i>MIT-BIH Arrhythmia Database</i>	65
Figura 29 - Sobreposição do sinal pré-processado com o sinal resultante do processamento intrínseco ao detetor de picos. O sinal utilizado foi o sinal mit103 da <i>MIT-BIH Arrhythmia Database</i>	66
Figura 30 - Diagrama de blocos referente à lógica de detecção de picos R.	67
Figura 31 - Diagrama de blocos referente à lógica de detecção de picos Q e S.	67
Figura 32 - Resultado de detecção, com a indicação da localização dos picos Q, R e S. O sinal utilizado foi o sinal mit103 da <i>MIT-BIH Arrhythmia Database</i>	69
Figura 33 - Pequeno segmento do vetor BPM relativo ao sinal mit119 da <i>MIT-BIH Arrhythmia Database</i> . Evidenciam-se 5 ocorrências de ESV, onde se verifica um pico de amplitude anormalmente baixo precedido de um pico anormalmente elevado.	70
Figura 34 - Derivada da frequência cardíaca instantânea (dBPM).....	71
Figura 35 - Diagrama de blocos geral do algoritmo detector de ESV.	71
Figura 36 - Diagrama de blocos ilustrativo da lógica de detecção de ESV no algoritmo proposto. Os índices n correspondem a posições de ESV no vetor de picos R.	72
Figura 37 - Exemplo de algumas características extraídas através de medição de amplitudes e durações. O ciclo cardíaco apresentado é uma ESV do sinal mit119 da <i>MIT-BIH Arrhythmia Database</i>	74
Figura 38 - Gráfico de dispersão de todas as instâncias dos cinco sinais utilizados neste trabalho, considerando as duas primeiras características do ranking de Kruskal Wallis. N - Normal. ESV - Extra-Sístole Ventricular.	82
Figura 39 - Diagrama de caixa para a distribuição da característica: Duração Q-S. Classe 0-batimento normal; Classe 1-ESV.	99
Figura 40 - Diagrama de caixa para a distribuição da característica: Máximo Negativo. Classe 0-batimento normal; Classe 1-ESV.	100
Figura 41 - Diagrama de caixa para a distribuição da característica: Declive de subida do complexo QRS. Classe 0-batimento normal; Classe 1-ESV.	100
Figura 42 - Diagrama de caixa para a distribuição da característica: Amplitude do pico R. Classe 0-batimento normal; Classe 1-ESV.	101
Figura 43 - Diagrama de caixa para a distribuição da característica: Diferença de amplitudes entre o pico R e o pico Q. Classe 0-batimento normal; Classe 1-ESV.	101

Figura 44 - Diagrama de caixa para a distribuição da característica: Razão entre a amplitude do pico R e a amplitude do pico Q. Classe 0-batimento normal; Classe 1-ESV.....	102
Figura 45 - Variação de SE com o parâmetro C na classificação por SVM, para <i>kernels</i> polinomiais de grau 1 a 5, utilizando o sinal mit119 para teste e os restantes para treino.....	104
Figura 46 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit119 para teste e os restantes para treino.	104
Figura 47 - Variação de SE com o parâmetro C na classificação por SVM, para <i>kernels</i> polinomiais de grau 1 a 5, utilizando o sinal mit213 para teste e os restantes para treino.....	105
Figura 48 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit213 para teste e os restantes para treino.	106
Figura 49 - Variação de SE com o parâmetro C na classificação por SVM, para <i>kernels</i> polinomiais de grau 1 a 5, utilizando o sinal mit215 para teste e os restantes para treino.....	107
Figura 50 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit215 para teste e os restantes para treino.	108
Figura 51 - Variação de SE com o parâmetro C na classificação por SVM, para <i>kernels</i> polinomiais de grau 1 a 5, utilizando o sinal mit223 para teste e os restantes para treino.....	110
Figura 52 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit223 para teste e os restantes para treino.	110
Figura 53 - Variação de SE com o parâmetro C na classificação por SVM, para <i>kernels</i> polinomiais de grau 1 a 5, utilizando o sinal mit233 para teste e os restantes para treino.....	111
Figura 54 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit233 para teste e os restantes para treino.	112

Lista de tabelas

Tabela 1 - Resultados das experiências, utilizando batimentos normais e ESV. SE - Sensibilidade; SP - Especificidade; P+ - Precisão [10].	51
Tabela 2 - Especificidade (SP) e Sensibilidade (SE) obtidas pelo algoritmo KNN com conjuntos de dados locais e globais [23].	52
Tabela 3 - Resultados de desempenho da classificação, obtidos com os diferentes métodos para as duas bases de dados (MIT e AHA) [24].	53
Tabela 4 - Sinais utilizados no presente trabalho. N - batimento normal; V - ESV.	58
Tabela 5 - Avaliação de desempenho do detetor de picos R. VP -Verdadeiro Positivo; FP-Falso Positivo; FN-Falso Negativo. SE-Sensibilidade; P+-Precisão.	79
Tabela 6 - Avaliação do desempenho do primeiro detetor de ESV. VP-Verdadeiros Positivos; VN-Verdadeiros Negativos; FP-Falsos Positivos; FN-Falsos Negativos; SE-Sensibilidade; SP-Especificidade, P+-Precisão.	80
Tabela 7 - Teste de Kruskal Wallis. O parâmetro H corresponde à estatística de Kruskal Wallis.	81
Tabela 8 - Análise do efeito da variação do parâmetro K no desempenho da classificação pelo algoritmo KNN, através do método <i>10-fold cross validation</i> . O valor mais elevado de sensibilidade é verificado para K=1 e encontra-se assinalado.	83
Tabela 9 - Análise do efeito da utilização de diferentes <i>kernels</i> no desempenho da classificação por SVM utilizando o método <i>10-fold cross validation</i> . Em cada um dos casos, o valor do parâmetro C é mantido constante e igual a 1. O valor mais elevado de sensibilidade é verificado para o <i>kernel</i> polinomial de grau 4 e encontra-se assinalado.	84
Tabela 10 - Verificação do melhor valor do parâmetro C a aplicar considerando um <i>kernel</i> polinomial de grau 4, utilizando uma classificação baseada no método <i>10-fold cross validation</i> . O valor mais elevado de SE é verificado em dois casos. Portanto, desses dois casos selecionou-se aquele em que se verificou um valor de especificidade mais elevado, que é para C = 0.1 (assinalado).	84
Tabela 11 - Teste de diferentes subconjuntos de características com o algoritmo SVM, com um <i>kernel</i> polinomial de grau 4 e parâmetro C=0.1. Encontra-se também representado o resultado da classificação com todas as características, para efeitos comparativos. A classificação foi efetuada recorrendo ao método <i>10-fold cross validation</i> .	85
Tabela 12 - Teste de diferentes subconjuntos de características com o algoritmo KNN, com K=1. Encontra-se também representado o resultado da classificação com todas as características, para efeitos comparativos. A classificação foi efetuada recorrendo ao método <i>10-fold cross validation</i> .	85
Tabela 13 - Matriz de correlação entre as diferentes características do subconjunto ótimo selecionado.	86

Tabela 14 - Comparação entre a classificação com as características do subconjunto ótimo e a classificação com os <i>Principal Components</i> , recorrendo aos algoritmos KNN com parâmetro $K=1$ e SVM com <i>kernel</i> polinomial de grau 4 e parâmetro $C=0.1$. A classificação foi efetuada recorrendo ao método <i>10-fold cross validation</i>	87
Tabela 15 - Classificação baseada no método <i>leave-one-out</i> , utilizando o algoritmo KNN com $K=1$	87
Tabela 16 - Classificação baseada no método <i>leave-one-out</i> , utilizando o algoritmo SVM, com um <i>kernel</i> polinomial de grau 4 e $C=0.1$	88
Tabela 17 - Comparação de desempenho entre primeiro algoritmo detetor de ESV e o classificador SVM, que apresentou melhores resultados em relação ao KNN.....	88
Tabela 18 - Teste das diferentes combinações de graus de <i>kernels</i> polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit119 para teste e os restantes para treino.	103
Tabela 19 - Teste dos diferentes valores de K na classificação por KNN, utilizando o sinal mit119 para teste e os restantes para treino.	104
Tabela 20 - Teste das diferentes combinações de graus de <i>kernels</i> polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit213 para teste e os restantes para treino.	105
Tabela 21 - Teste dos diferentes valores de K na classificação por KNN, utilizando o sinal mit213 para teste e os restantes para treino.	106
Tabela 22 - Teste das diferentes combinações de graus de <i>kernels</i> polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit215 para teste e os restantes para treino.	107
Tabela 23 - Teste dos diferentes valores de K na classificação por KNN, utilizando o sinal mit215 para teste e os restantes para treino	108
Tabela 24 - Teste das diferentes combinações de graus de <i>kernels</i> polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit223 para teste e os restantes para treino.	109
Tabela 25 - Teste dos diferentes valores de K na classificação por KNN, utilizando o sinal mit223 para teste e os restantes para treino	110
Tabela 26 - Teste das diferentes combinações de graus de <i>kernels</i> polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit233 para teste e os restantes para treino.	111
Tabela 27 - Teste das diferentes combinações de graus de <i>kernels</i> polynomial com parâmetros C na classificação por KNN, utilizando o sinal mit233 para teste e os restantes para treino.	112

Abreviaturas e Símbolos

AV	Auriculo-Ventricular
ES	Extra-Sístole
ECG	Eletrocardiograma
ESA	Extra-Sístole Auricular
ESV	Extra-Sístole Ventricular
FN	Falso Negativo
FP	Falso Positivo
KNN	<i>Kth Nearest-Neighbors Rule</i>
PVC	<i>Premature Ventricular Contraction</i>
P+	Precisão (parâmetro de eficácia de algoritmos)
RS	Retículo Sarcoplasmático
SA	Sinusal
SE	Sensibilidade (parâmetro de eficácia de algoritmos)
Sinal ECG	Sinal eletrocardiográfico
SP	Especificidade (parâmetro de eficácia de algoritmos)
SVM	<i>Support Vector Machines</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

Capítulo 1

Introdução

As extra-sístoles ventriculares (ESV) de uma forma geral constituem irregularidades no ritmo cardíaco em que uma batida ocorre imediatamente depois de uma batida normal, seguida de um longo intervalo até recomeçar o ritmo normal. Podem ser muito raras ou ocorrer várias vezes por minuto. Também podem ocorrer de forma ocasional em pessoas saudáveis. As causas deste fenómeno são inúmeras e existem muitos casos em que não é encontrada uma causa expressiva. Por vezes, o consumo excessivo de substâncias como álcool, cafeína, tabaco e drogas pesadas (ex.: cocaína) pode estar na origem deste fenómeno, e neste caso as extra-sístoles são benignas. Noutros casos, a presença de extra-sístoles está relacionada com patologias cardíacas graves, e neste caso elas são malignas. Tendo em conta que as extra-sístoles são distinguíveis de batidas normais num exame eletrocardiográfico, evidencia-se a importância da existência de dispositivos de monitorização do sinal ambulatorio ECG. Estes dispositivos permitem tipificar o padrão de ocorrência de extra-sístoles de forma a diagnosticar patologias cardíacas potencialmente perigosas. Se estes dispositivos de monitorização forem programados para soar alarmes quando detetam extra-sístoles em pacientes com patologias cardíacas severas, podem ser evitadas situações graves.

Atualmente, o monitor Holter é o dispositivo utilizado para o registo ambulatorio de longa duração da atividade eletrocardiográfica de pacientes, tendo em vista sua monitorização. O período de gravação de ECG levado a cabo por este dispositivo é de pelo menos 24 horas. Este longo período de gravação é por vezes útil para a observação de arritmias cardíacas ocasionais ou eventos epiléticos, os quais seriam difíceis de identificar num curto período de tempo. Quando a gravação de sinal é finalizada, cabe então a um médico da especialidade fazer a análise do sinal de modo a detetar eventos anormais. A criação de aplicações de *software* automáticas para deteção de extra-sístoles constitui uma ajuda significativa no trabalho dos especialistas, uma vez que permite uma poupança no tempo de análise dos ECG facilitando a execução do processo.

O texto acima consistiu numa breve introdução ao tema em estudo. A seguir, são indicados os conteúdos de cada um dos restantes capítulos desta dissertação.

No Capítulo 2 é feito um enquadramento conceptual acerca dos fenómenos associados ao funcionamento do coração. Descreve-se a morfologia do sinal ECG e os desvios que as ESV induzem no sinal.

O Capítulo 3 constitui a revisão do estado da arte. Inicialmente são referidas técnicas de processamento de sinal ECG. Depois, descrevem-se técnicas de reconhecimento de padrões específicos em sinais ECG em termos de características utilizadas na discriminação e algoritmos de classificação utilizados.

O Capítulo 4 é a maior secção desta dissertação e é aquele que descreve todo o trabalho que envolveu este projeto. São descritas as metodologias utilizadas e apresentam-se e discutem-se os resultados obtidos.

Por fim, no Capítulo 5 são apresentadas as conclusões gerais do trabalho e as perspetivas futuras.

Capítulo 2

Enquadramento Conceptual

2.1 - Introdução

Neste capítulo são descritos os mecanismos de formação e condução dos impulsos elétricos cardíacos, analisa-se a forma de onda do sinal ECG e a forma como este sinal é recolhido. É também feita a associação dos diferentes componentes da forma de onda do sinal ECG com os diferentes estágios da condução de impulsos elétricos no coração. Posteriormente, descrevem-se os mecanismos que levam à ocorrência de ESV e representam-se as morfologias de sinal associadas a este tipo de arritmia. Por fim, tecem-se algumas considerações acerca da relevância clínica das ESV.

2.2 - O sistema de condução do coração

O funcionamento do coração baseia-se na condução de impulsos bio-elétricos. A fonte desta atividade elétrica é uma rede de fibras musculares cardíacas especializadas, as fibras autorritmicas, que têm esta designação devido ao facto de serem auto-excitáveis. Estas fibras geram potenciais de ação repetidamente, os quais desencadeiam as contrações do coração. Em cenários de transplante de coração, elas continuam a estimular o batimento do coração mesmo depois de este ter sido removido do corpo e todos os seus nervos terem sido cortados. Durante o desenvolvimento embrionário, apenas cerca de 1% das fibras musculares cardíacas se desenvolvem em fibras autorritmicas. Estas fibras especializadas desempenham duas importantes funções: (1) atuam como *pacemaker*, ajustando o ritmo da excitação elétrica que causa a contração do coração; (2) formam o sistema de condução do coração, uma rede especializada de fibras musculares cardíacas que fornece um meio de condução elétrica para a progressão de cada ciclo de excitação cardíaca. O sistema de condução assegura que as cavidades cardíacas sejam estimuladas de forma a contraírem coordenadamente, o que torna o coração uma bomba efetiva. Problemas relacionados com as fibras autorritmicas podem resultar em arritmias, que são batimentos cardíacos irregulares. Os potenciais de ação cardíacos propagam-se ao longo do sistema de condução da seguinte forma (Figura 1) [1]:

1. A excitação cardíaca inicia-se normalmente no nó sinusal (SA), localizado na parede auricular direita numa posição inferior e lateral em relação à abertura da veia cava superior¹ (Figura 1). As células do nó SA não possuem um potencial de repouso estável. Em vez disso, elas despolarizam-se acima de um limiar repetidamente e espontaneamente. Esta despolarização espontânea é um potencial marca-passo

¹ Uma das duas principais veias sistémicas, que recolhe o sangue do organismo e desemboca na aurícula direita.

(*pacemaker*). Quando o potencial marca-passo atinge um determinado limiar, é desencadeado um potencial de ação (Figura 2). Cada potencial de ação gerado no nó SA propaga-se por toda a área das duas aurículas, através de junções comunicantes presentes nas fibras musculares das aurículas. Após o potencial de ação, as duas aurículas contraem ao mesmo tempo [1].

2. Através da condução ao longo das fibras musculares auriculares, o potencial de ação atinge o nó auriculoventricular (AV), localizado no septo interauricular. No nó AV, o potencial de ação abranda consideravelmente, em resultado de várias diferenças na estrutura das células nas imediações deste nó. O atraso na propagação do potencial de ação proporciona o tempo necessário para que as aurículas se esvaziem, passando todo o sangue para os ventrículos [1].
3. A partir do nó AV, o potencial de ação insere-se no feixe auriculoventricular (AV), também conhecido como feixe de His. Este feixe é o único local pelo qual os potenciais de ação podem ser conduzidos das aurículas para os ventrículos. Nos outros locais, o esqueleto fibroso do coração isola eletricamente as aurículas dos ventrículos [1].
4. Através da propagação ao longo do feixe de His, o potencial de ação entra em cada um dos ramos (direito e esquerdo) do feixe de His. Estes ramos estendem-se em direção ao ápice do coração, através do septo interventricular [1].
5. Por último, as fibras de Purkinje, de diâmetro considerável, conduzem rapidamente o potencial de ação a partir do ápice do coração para cada um dos lados numa direção ascendente. Assim, o potencial propaga-se ao miocárdio² das paredes laterais de cada um dos ventrículos. Em seguida os ventrículos contraem, empurrando o sangue em direção às válvulas semilunares³ [1].

Por si só, as fibras autorritmicas no nó sinusal iniciam um potencial de ação a cada 0.6 segundos, ou seja, 100 vezes em cada minuto. Esta taxa é mais rápida do que a de outras fibras autorritmicas. Devido ao facto dos potenciais de ação a partir do nó sinusal se espalharem através do sistema de condução e estimularem outras áreas antes de essas áreas serem capazes de gerar um potencial de ação por si próprias, o nó sinusal atua como o marca-passo natural do coração. Impulsos nervosos a partir do sistema nervoso autónomo e hormonas transmissíveis pelo sangue modificam o *timing* e o vigor de cada batimento cardíaco, mas não estabelecem o ritmo fundamental. Numa pessoa em repouso, por exemplo, a libertação de neurotransmissores reduz o ritmo de desencadeamento de potenciais de ação pelo nó SA para cerca de um potencial a cada 0.8 segundos (75 potenciais de ação por minuto) (Figura 2) [1].

² Parede muscular do coração.

³ Válvulas que se localizam na abertura das artérias que recolhem o sangue dos ventrículos. Têm a função de impedir o refluxo sanguíneo para os ventrículos.

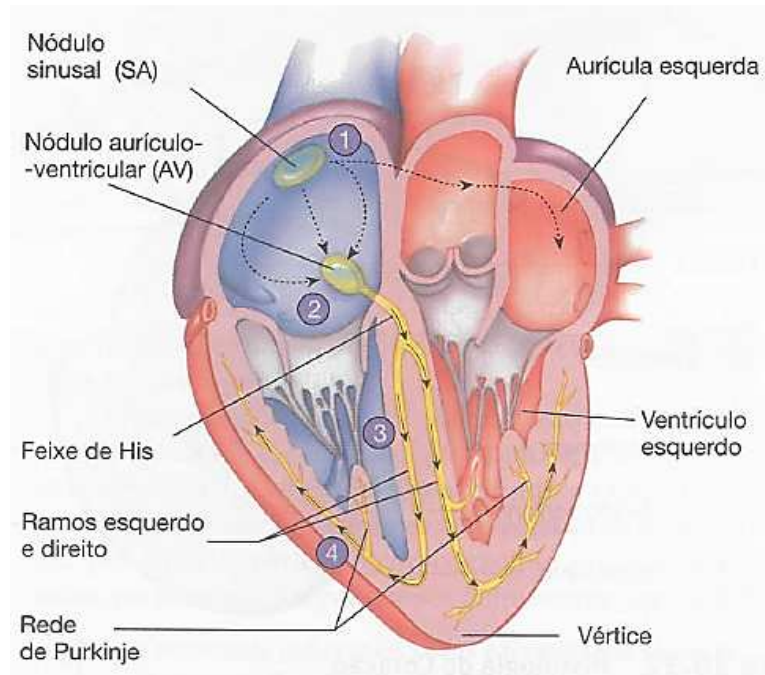


Figura 1 - Sistema de condução de coração, indicando por meio de setas a direção de propagação dos potenciais de ação. Nota: os números da figura não coincidem com os números que representam as fases do ciclo de condução no texto. 1-Origem dos potenciais de ação no nó SA e sua propagação através da parede da aurícula até ao nó AV; 2-Propagação dos potenciais pelo nó AV e pelo feixe de His, que se estende desde o nó AV até ao septo interventricular; 3-Os potenciais de ação descem para o vértice de cada ventrículo através de cada um dos ramos do feixe de His; 4-Os potenciais de ação são transportados pelas fibras de Purkinje até às paredes ventriculares [2].




Figura 2 - Potenciais marca-passo e potenciais de ação nas fibras autorritmicas do nó SA [1].

2.3 - Potencial de ação e contração das fibras contrácteis

O potencial de ação iniciado pelo nó SA propaga-se ao longo do sistema de condução e espalha-se de forma a excitar as fibras musculares auriculares e ventriculares, chamadas fibras contrácteis. Um potencial de ação ocorre numa fibra contráctil de acordo com os seguintes passos (Figura 3) [1]:

1. **Despolarização.** Ao contrário das fibras autorrítmicas, as fibras contrácteis possuem um potencial de membrana de repouso estável, cujo valor é de cerca de -90 mV. Quando o potencial de membrana de uma fibra contráctil é levado a atingir um determinado limiar devido a um potencial de ação oriundo de fibras vizinhas, os seus canais rápidos de Na^+ dependentes de voltagem abrem. Estes canais são referidos como rápidos uma vez que abrem muito rapidamente em resposta a uma despolarização acima do limiar. A abertura destes canais permite a entrada de iões Na^+ , uma vez que o citosol⁴ das fibras contrácteis é eletricamente mais negativo do que o fluido intersticial e a concentração de Na^+ é mais alta no fluido intersticial. A entrada de Na^+ a favor do gradiente eletroquímico conduz então a uma rápida despolarização. Em poucos milissegundos os canais de Na^+ ficam automaticamente inativados e a entrada de Na^+ diminui [1].
2. **Plateau.** A fase seguinte de um potencial de ação numa fibra contráctil é o *plateau*, um período de manutenção da despolarização. Em parte, é devido à abertura dos canais lentos de Ca^{2+} dependentes de voltagem no sarcolema⁵. Quando estes canais abrem, os iões cálcio movem-se a partir do fluido intersticial (onde existe uma maior concentração destes iões) para o citosol. Esta entrada de Ca^{2+} causa uma presença ainda maior destes iões no retículo sarcoplasmático⁶ (RS), devido à passagem dos mesmos por canais adicionais de Ca^{2+} na membrana do RS. Assim, ainda mais iões cálcio estão disponíveis no RS para migrar para o citosol, caso seja necessário. A concentração aumentada de Ca^{2+} no citosol causa, por fim, a contração. Vários tipos de canais de K^+ dependentes de potencial estão também integrados no sarcolema de uma fibra contráctil. Imediatamente antes do início da fase de *plateau*, alguns desses canais de K^+ abrem, permitindo a passagem dos iões potássio para fora da fibra muscular. Portanto, a despolarização é mantida durante a fase de *plateau*, uma vez que a entrada de iões cálcio numa fibra é contrabalançada pela saída de iões potássio. A fase de *plateau* dura cerca de 0.25 segundos, e durante essa fase o potencial de membrana da fibra tem um valor próximo de 0 mV. Comparativamente, a despolarização num neurónio ou numa fibra muscular esquelética é muito mais rápida, de cerca de 1 milissegundo, porque nestes casos a fase de *plateau* não existe [1].
3. **Repolarização.** A recuperação do potencial de membrana de repouso durante a fase de repolarização de um potencial de ação cardíaco é semelhante ao que acontece em outras células excitáveis. Depois de um atraso, o qual é particularmente prolongado no caso do músculo cardíaco, abrem-se canais de K^+ dependentes de voltagem adicionais. A saída de iões potássio restabelece o potencial de membrana de repouso negativo (-90 mV). Ao mesmo tempo, os canais de cálcio no sarcolema e no retículo

⁴ Líquido armazenado no interior das células.

⁵ Designação da membrana celular das células do tecido muscular.

⁶ Cavidade das células musculares especializada no armazenamento de iões cálcio, provocando a contração muscular quando liberta esses iões para o seio das células.

sarcoplasmático estão a fechar-se, o que também contribui para a repolarização. O mecanismo de contração do músculo cardíaco é similar ao do músculo esquelético: a atividade elétrica (potencial de ação) leva a uma resposta mecânica (contração) após um pequeno atraso. Como a concentração de Ca^{2+} aumenta dentro de uma fibra contráctil, estes iões ligam-se à proteína reguladora troponina⁷, o que permite que os filamentos de actina e miosina deslizem uns sobre os outros, começando a tensão muscular a desenvolver-se. As substâncias que alteram o movimento de iões cálcio através dos canais lentos de Ca^{2+} influenciam a força das contrações do coração. A epinefrina, por exemplo, aumenta a força de contração por aumentar o fluxo de Ca^{2+} para o citosol. No músculo, o período refratário é o intervalo de tempo durante o qual uma segunda contração não pode ser desencadeada. O período refratário de uma fibra muscular cardíaca dura mais do que a própria contração. Como resultado, uma outra contração não pode começar enquanto o relaxamento estiver em curso. Por esta razão, o tétano⁸ não se pode manifestar no músculo cardíaco. A vantagem é evidente, se se tiver em consideração a forma como os ventrículos funcionam. A sua função de bombeamento depende da ocorrência de contrações (quando ejetam sangue) e de relaxamentos (quando se reabastecem de sangue) alternadamente. Se o tétano pudesse ocorrer no músculo cardíaco, o fluxo sanguíneo cessaria [1].

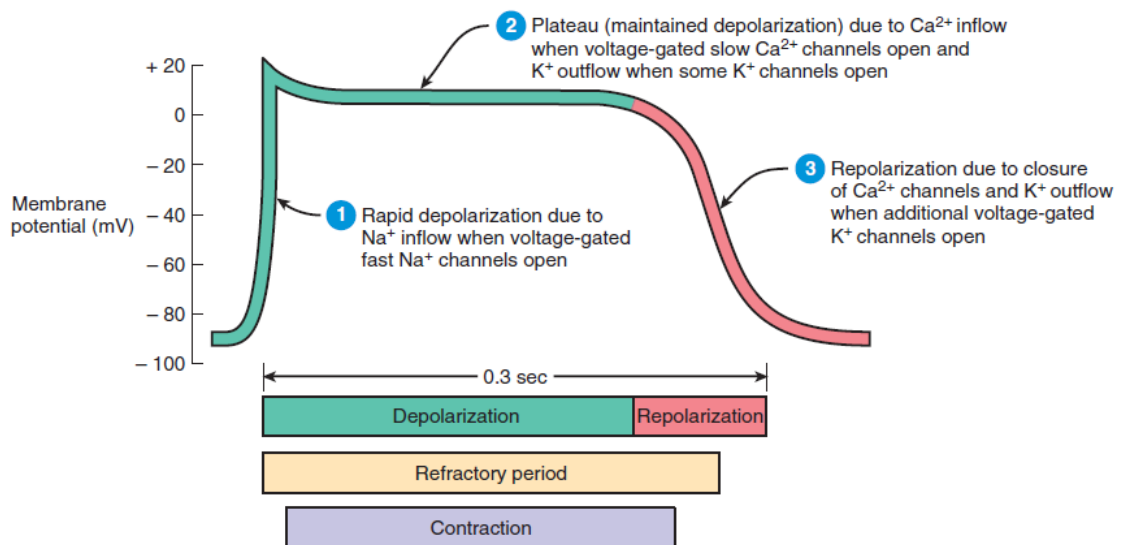


Figura 3 - Potencial de ação numa fibra contráctil. O potencial de repouso da membrana é de cerca de -90 mV [1].

⁷ Complexo de três proteínas que participam no processo de contração muscular.

⁸ Doença infecciosa grave que se caracteriza por contrações musculares persistentes.

2.4 - Eletrocardiografia

Uma vez que se propagam potenciais de ação ao longo do coração, eles geram correntes elétricas que podem ser detetadas à superfície do corpo através de um eletrocardiograma (ECG), que consiste num registo desses sinais elétricos. Estes potenciais de ação manifestam-se na forma de ondas de sinal (Figura 4). O instrumento utilizado para registar estes eventos é o eletrocardiógrafo, que é projetado para captar somente o intervalo de frequências de interesse dos sinais ECG. Na prática clínica, são posicionados elétrodos nos braços e nas pernas (derivações dos membros), e em seis posições no peito (derivações do peito) para realizar o registo de um ECG de rotina. A disposição dos elétrodos permite obter 12 derivações de sinal. Este método será explicado mais em pormenor na secção 2.5. Num registo de ECG típico, três ondas claramente reconhecíveis aparecem associadas a cada batimento cardíaco (Figura 4) [1].

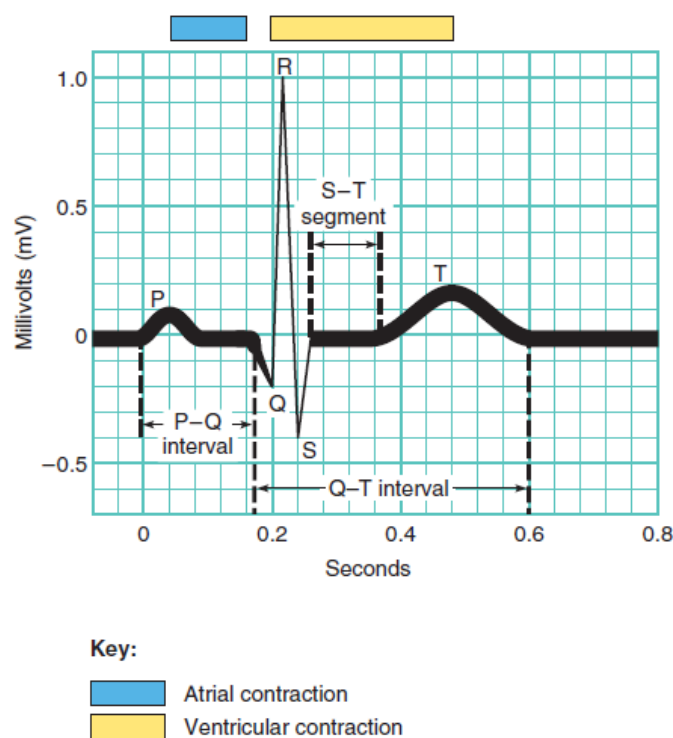


Figura 4 - Eletrocardiograma normal. Onda P: despolarização auricular; Complexo QRS: início da despolarização ventricular; Onda T: repolarização ventricular [1].

A primeira onda, denominada onda P, consiste numa pequena deflexão ascendente. Esta onda representa a despolarização auricular, a qual se espalha desde o nó SA até às fibras contrácteis de ambas as aurículas [1].

A segunda onda, denominada complexo QRS, começa com uma deflexão descendente, continuando depois com uma grande onda triangular e acabando como uma onda ascendente. O complexo QRS representa a rápida despolarização ventricular, à medida que o potencial de ação se espalha através das fibras contrácteis ventriculares.

A terceira onda, denominada onda T, consiste numa deflexão ascendente em forma de cúpula. Esta última onda representa a repolarização ventricular e ocorre quando os ventrículos iniciam a sua fase de relaxamento. A onda T é mais pequena em amplitude mas

mais prolongada que o complexo QRS, porque a repolarização ocorre de uma forma mais lenta do que a despolarização. Durante o período de *plateau* de despolarização estacionária, o traçado do ECG é plano. Na leitura de um ECG, a observação dos tamanhos das diferentes ondas pode fornecer importantes indicações de anomalias. Ondas P mais largas do que o normal indicam a dilatação de uma aurícula, uma onda Q mais larga pode indicar um enfarte do miocárdio, e uma onda R mais larga indica de uma forma geral uma dilatação dos ventrículos. A onda T apresenta-se mais achatada do que o normal quando o músculo cardíaco não recebe oxigénio suficiente, como por exemplo na doença da artéria coronária. Esta onda pode ainda apresentar-se mais elevada em situações de excesso de iões K^+ no sangue [1].

A análise de um ECG envolve também a medição dos intervalos de tempo entre as ondas. Por exemplo, o intervalo P-Q, entre o início da onda P e o início do complexo QRS, corresponde ao tempo necessário para o potencial de ação se propagar pelas aurículas, pelo nó AV e pelas restantes fibras do sistema de condução. Se o potencial de ação for forçado a desviar-se de tecido cicatricial causado por patologias como a doença da artéria coronária e a febre reumática⁹, o intervalo P-Q prolonga-se [1].

O segmento S-T, que começa no fim da onda S e termina no início da onda T, representa o tempo durante o qual as fibras contrácteis ventriculares estão despolarizadas durante a fase de *plateau* do potencial de ação. O segmento S-T é elevado (acima da linha de base) em caso de enfarte agudo do miocárdio, e rebaixado (abaixo da linha de base) quando o músculo cardíaco não recebe oxigénio suficiente [1].

O intervalo Q-T estende-se desde o início do complexo QRS até ao fim da onda T, e representa o tempo desde o início da despolarização ventricular até ao fim da repolarização ventricular. Este intervalo pode ser prolongado em caso de danos no miocárdio, isquemia¹⁰ do miocárdio, ou anomalias de condução. Por vezes é útil a avaliação da resposta do coração ao stress proporcionado pelo exercício físico (prova de esforço), porque as artérias coronárias estreitadas, apesar de poderem transportar adequadamente sangue oxigenado enquanto uma pessoa está em repouso, não serão capazes de satisfazer as necessidades crescentes de oxigénio no coração durante um exercício vigoroso. Esta situação provoca mudanças que podem ser detetadas num eletrocardiograma. Ritmos cardíacos anormais e fluxo sanguíneo inadequado para o coração podem por vezes ocorrer apenas instantaneamente ou imprevisivelmente. Para detetar estes problemas, são utilizados eletrocardiógrafos ambulatoriais contínuos. Com este procedimento, uma pessoa utiliza um monitor que funciona com bateria (monitor Holter) e que grava um ECG continuamente por 24 horas. Eléctrodos ligados ao peito são ligados a um monitor, e a informação da atividade cardíaca é armazenada no monitor e analisada posteriormente por pessoal competente [1]. Este tipo de monitores será analisado em detalhe na secção 2.8.

⁹ Inflamação generalizada que pode afetar várias partes do corpo, incluindo o coração.

¹⁰ Falta de suprimento sanguíneo.

2.5 - ECG de 12 Derivações

O ECG de 12 derivações fornece bastante mais informações sobre o coração do que o de uma única derivação, o qual fornece apenas informação sobre o ritmo e frequência cardíaca. O ECG de 12 derivações pode alertar os médicos para anomalias congênitas ou adquiridas no coração, doença do pericárdio¹¹, miocárdio ou endocárdio¹². Além disso, este método de aquisição de sinal ECG permite a obtenção de informações importantes acerca do estado da circulação coronária e da perfusão no miocárdio durante a anestesia [3].

O ECG de 12 derivações capta a atividade elétrica do coração a partir de 12 pontos de vista ou direções diferentes, o que permite a posterior organização dessa informação de modo a ser mostrada em 12 gráficos diferentes. As 12 derivações dividem-se da seguinte forma [3]:

- I, II, III - São as três derivações bipolares dos membros;
- aVR, aVL, aVF - São as três derivações unipolares dos membros;
- V1, V2, V3, V4, V5, V6 - São as seis derivações unipolares do peito.

As 12 derivações dividem-se em dois planos: o plano frontal, que inclui as derivações dos membros; o plano horizontal, que inclui as derivações do peito [3].

As três primeiras derivações dos membros (I, II e III) são designadas bipolares porque medem a diferença no potencial elétrico entre dois elétrodos. A derivação I mede a diferença de potencial entre os braços direito e esquerdo, a II mede a diferença de potencial entre a perna esquerda e o braço direito e a derivação III mede a diferença de potencial entre a perna esquerda e o braço esquerdo. O triângulo formado por estas três derivações é designado triângulo de Einthoven e o coração está localizado no centro desse triângulo (Figura 5-A) [3].

As derivações aVR, aVL e aVF são designadas unipolares, porque cada uma delas inclui um eletrodo positivo com o ponto de referência elétrica negativa localizado teoricamente no centro do coração. Portanto, estas derivações sondam o coração a partir do ombro direito (aVR), do ombro esquerdo (aVL) e do pé da perna esquerda (aVF) (Figura 5-B) [3].

¹¹ Membrana externa que envolve o coração.

¹² Camada interna do coração, da qual fazem parte as válvulas cardíacas.

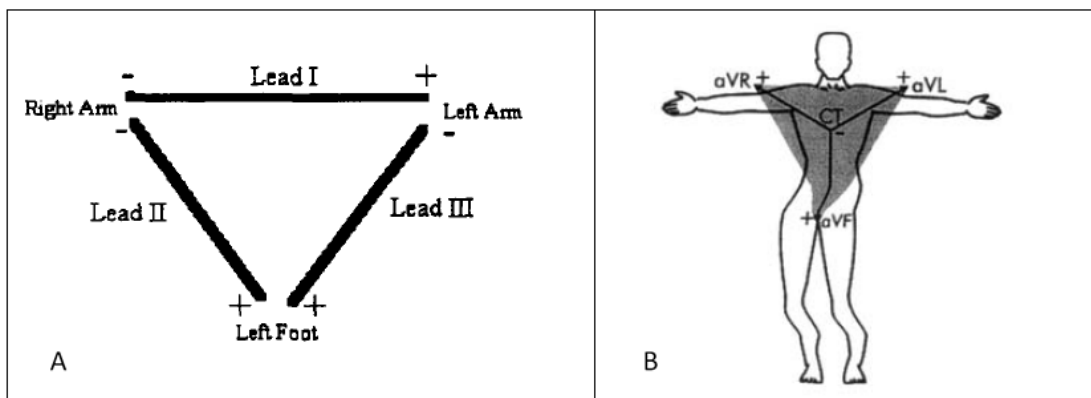


Figura 5 - Derivações do plano frontal. (A) Triângulo de Einthoven formado pelas derivações I, II e III; (B) Derivações unipolares dos membros, aVR, aVL e aVF [3].

As derivações do peito sondam a atividade elétrica do coração a partir do plano horizontal. Estas derivações são unipolares e cada uma delas usa o centro elétrico do coração como ponto de referência para o elétrico positivo. Os eletrodos das derivações do peito são posicionados nos espaços intercostais de V1 a V6 e o posicionamento correto dos eletrodos (Figura 6-A) é imperativo para evitar a detecção de falsas anomalias. Anatomicamente, as derivações do peito sondam a parte anterior do coração e assume-se uma convenção em que as derivações V1 e V2 sondam o ventrículo direito, V3 e V4 sondam o septo interventricular e V5 e V6 sondam o ventrículo esquerdo (Figura 6-B) [3].

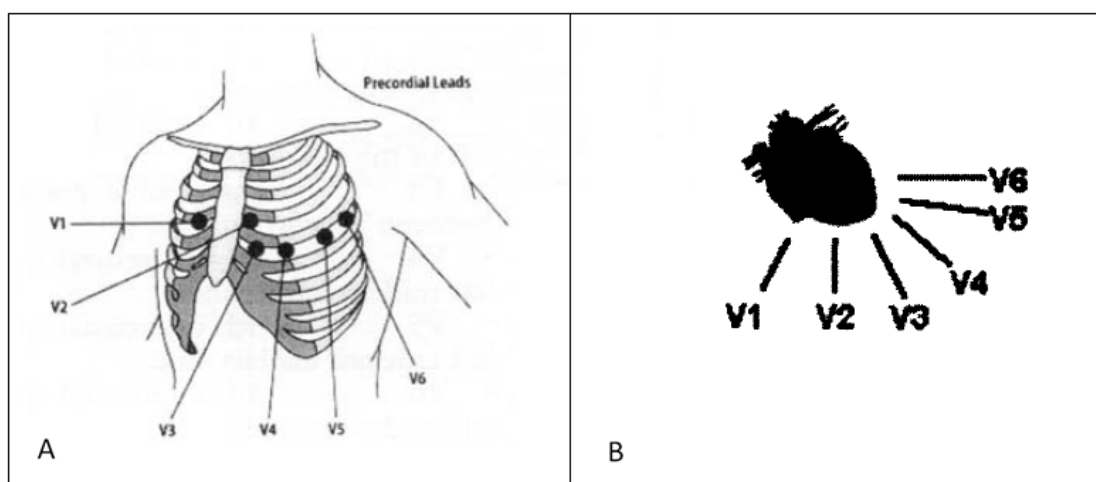


Figura 6 - Derivações do peito. (A) posicionamento dos eletrodos nos espaços intercostais; (B) Distribuição das derivações pelos diferentes espaços do coração [3].

Na montagem do ECG de 12 derivações, além dos seis eletrodos das derivações do plano frontal e dos seis eletrodos das derivações do peito, é também posicionado um eletrodo na perna direita. Este eletrodo não tem a função de sondar a atividade elétrica do coração, sendo a sua função a de “terra” do sistema. Assim, as medições dos restantes eletrodos são efetuadas em relação a uma referência comum, o que é essencial para a obtenção de resultados estáveis [3].

2.6 - Correlação das ondas ECG com as sístoles auricular e ventricular

Tal como já foi descrito na secção 2.4, as aurículas e os ventrículos despolarizam e depois contraem em diferentes instantes de tempo, uma vez que o sistema de condução encaminha os potenciais de ação ao longo de um caminho específico. O termo “sístole” refere-se à fase de contração, enquanto que a fase de relaxamento é denominada “diástole”. As ondas de ECG constituem uma indicação da sequência das sístoles e diástoles auriculares e ventriculares. A uma taxa de 75 batimentos por minuto, a sequência é da seguinte forma (Figura 7) [1]:

1. Um potencial de ação cardíaco surge no nó SA. Este propaga-se para toda a área muscular das aurículas e numa direção descendente para o nó AV em cerca de 30 milissegundos. Como as fibras contrácteis auriculares despolarizam, a onda P aparece no ECG [1].
2. Depois do início da onda P, as aurículas contraem (sístole auricular). A condução do potencial de ação abranda no nó AV, uma vez que nesse local as fibras musculares possuem diâmetros mais pequenos e junções comunicantes mais escassas. O resultado disto é um atraso de 0.1 segundos na propagação do potencial de ação, o que proporciona às aurículas tempo para contrair, passando o seu sangue para os ventrículos antes do início da sístole ventricular [1].
3. Depois de entrar no feixe AV, o potencial de ação volta a propagar-se a uma velocidade maior. Em cerca de 0.2 segundos após o começo da onda P, o potencial ter-se-á já propagado aos ramos do feixe AV, às fibras de Purkinje e a todo o miocárdio ventricular. A despolarização progride abaixo do septo interventricular para cima a partir do ápice e para fora da superfície endocárdica, produzindo o complexo QRS. Ao mesmo tempo, ocorre a repolarização auricular, mas geralmente não é evidente num ECG porque é mascarada pelo grande complexo QRS [1].
4. A contração das fibras ventriculares contrácteis (sístole ventricular) tem início logo após o aparecimento do complexo QRS e continua durante o segmento S-T. Como a contração prossegue desde o ápice em direção à base do coração, o sangue é forçado a mover-se para cima em direção às válvulas semilunares [1].
5. A repolarização das fibras contrácteis ventriculares começa no ápice e espalha-se por todo o miocárdio ventricular. Este evento produz a onda T no ECG em cerca de 0.4 segundos após o início da onda P [1].
6. Logo após o início da onda T, os ventrículos começam a relaxar (diástole ventricular). Aos 0.6 segundos, a repolarização ventricular é completada e as fibras ventriculares contrácteis são relaxadas [1].

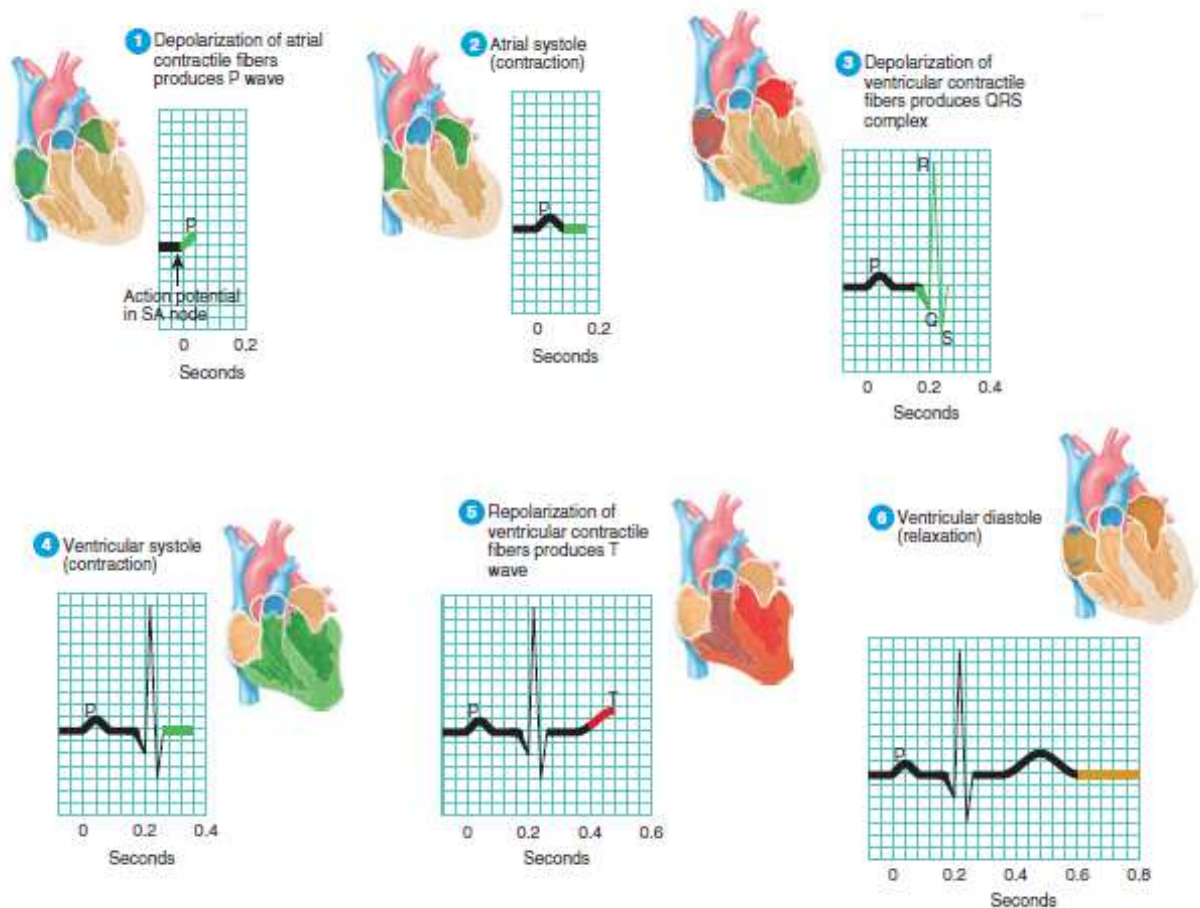


Figura 7 - Caminho e *timing* das despolarizações e repolarizações ao longo do sistema de condução e miocárdio visíveis num ECG. Os traços a verde indicam despolarização e os traços vermelhos indicam repolarização [1].

Durante os 0.2 segundos seguintes aos passos acima enumerados, as fibras contrácteis das aurículas e dos ventrículos estão relaxadas. Aos 0.8 segundos, a onda P aparece novamente no ECG e as aurículas começam novamente a contrair, repetindo-se o ciclo [1].

2.7 - Arritmias Cardíacas

O ritmo habitual dos batimentos cardíacos estabelecido pelo nó sinusal designa-se por ritmo sinusal normal. O termo arritmia é usado para referir um ritmo anormal, que é o resultado de um defeito no sistema de condução do coração. A irregularidade dos batimentos cardíacos pode consistir quer num ritmo mais acelerado, quer num ritmo mais lento do que o normal. Os sintomas de arritmias incluem dores no peito, falta de ar, sensação de fraqueza, tontura e desmaios. As arritmias podem ser causadas por agentes estimuladores do coração tais como situações de stress, consumo de cafeína, álcool, nicotina, cocaína e outras drogas. As arritmias podem também ser causadas por defeitos congénitos, pela doença da artéria coronária, por enfarte do miocárdio, hipertensão, válvulas cardíacas defeituosas, cardiopatia reumática¹³, hipertireoidismo¹⁴, e deficiência de potássio [1].

¹³ Danos crónicos das válvulas cardíacas.

As arritmias são categorizadas pela sua velocidade, ritmo e origem do problema. A bradicardia é uma arritmia que consiste numa frequência cardíaca baixa (abaixo de 50 batimentos por minuto). Por sua vez, a taquicardia consiste numa frequência cardíaca acelerada (acima de 100 batimentos por minuto). A fibrilação é uma arritmia em que a frequência cardíaca é acelerada e os batimentos são descoordenados. As arritmias que se iniciam nas aurículas são denominadas supraventriculares ou auriculares. As arritmias que são originadas nos ventrículos designam-se ventriculares [1].

2.8 - Gravação de ECG em regime ambulatorio

As anomalias no ritmo cardíaco são relativamente comuns. Algumas não são prejudiciais, mas outras prenunciam situações de muito perigo, como paragem cardíaca. Portanto, a deteção e quantificação deste tipo de arritmias é importante, especialmente para pacientes que possuem patologia cardíaca estrutural causada por um evento como um ataque cardíaco. As arritmias são frequentemente limitadas em duração e a sua ocorrência não é detetada durante um ECG de rotina, uma vez que este dura apenas alguns segundos. Para fazer o diagnóstico de arritmias e avaliar a sua relação com os sintomas do paciente, ou para avaliar a efetividade de uma intervenção para as suprimir, são necessários longos períodos de gravação de ECG durante o decorrer da vida quotidiana do paciente [4].

O método generalizado de realização deste tipo de gravações de ECG é o monitor Holter (tem o nome do seu inventor, Norman Holter), que inclui um sistema de armazenamento de sinal ECG, que é posteriormente processado e enviado a um médico para análise. Tradicionalmente, estas gravações têm um período de 24 ou 48 horas, e são feitas através de 3 a 5 elétrodos posicionados no peito, que permitem a aquisição de três representações de sinal (dois vetores de ECG e um terceiro correspondente a uma derivação). Os dispositivos mais antigos armazenavam a informação em fita de cassette e os mais recentes armazenam a informação num dispositivo de memória *flash* [4]. Em alguns destes sistemas pode ser realizada uma aquisição de 12 derivações, o que se torna útil na análise da morfologia do complexo QRS. Os sistemas disponíveis atualmente apresentam uma frequência de amostragem típica de 250 Hz, sendo a menor verificada igual a 200 Hz [5]. Este valor mínimo é ainda cinco vezes maior do que a maior frequência verificada no espectro do sinal ECG, cujo valor é 40 Hz (Figura 8).

¹⁴ Hiperfunção da glândula tireóide, com produção excessiva de hormona tiroideia.




Figura 8 - Espectro de frequências da onda P, complexo QRS e onda T do sinal ECG. As localizações dos diferentes componentes no espectro correspondem a uma aproximação um pouco grosseira, uma vez estas localizações variam consideravelmente de acordo com o indivíduo, derivação de sinal associada e origem do batimento cardíaco analisado (ex.: batimento normal, extra-sístole, etc.) [6].

Em geral, podemos dividir os dispositivos de monitorização de ECG de longa duração em duas classes: os dispositivos que armazenam continuamente os dados que estão a ser monitorizados, e os dispositivos que armazenam os dados monitorizados de uma forma intermitente. Estes últimos podem ser de dois tipos:

- *Event recorders*. Armazenam os dados que estão a ser monitorizados após a ativação por parte do utilizador, em resposta à sua perceção de um sintoma;
- *Loop recorders*. Gravam provisoriamente os dados que estão a ser monitorizados mantendo em memória sempre a mesma quantidade de dados. Assim, os dados mais recentes vão substituindo os dados mais antigos. Em resposta a uma ativação do utilizador, o dispositivo armazena de forma permanente os dados monitorizados num intervalo compreendido entre alguns minutos antes e alguns minutos após a ativação [4].

Mais recentemente, outros dispositivos de monitorização de ECG de longa duração foram desenvolvidos. Entre estes, incluem-se vários dispositivos de monitorização por telemetria e monitores do tipo Holter com capacidade de armazenar dados por mais tempo [5].

Os monitores por telemetria têm uma grande capacidade de armazenamento de dados (até 30 dias). No sistema *sensor only*, quando o utilizador está numa zona com suficiente cobertura de rede telefónica, os dados armazenados são enviados diretamente para uma estação central de monitorização. Mais habitualmente, estes sistemas de monitorização incorporam um segundo dispositivo que é separado do dispositivo de aquisição de dados. Assim, quando o utilizador se aproxima suficientemente deste segundo dispositivo, os dados são enviados, por exemplo, via *wireless* e armazenados neste [5].

Outra alternativa recentemente desenvolvida (*Zio Patch, iRhythm Technologies, San Francisco, California*) utiliza um sensor pequeno, leve e à prova de água que é colocado na zona do peito esquerdo e pode armazenar até 14 dias de dados da monitorização contínua da diferença de potencial entre apenas dois elétrodos (*one lead*). Estes dispositivos apresentam também um botão que quando premido, permite a posterior identificação daquele momento como um instante em que ocorreu um sintoma [5].

2.9 - Definição de Extra-Sístole

Extra-sístole (ES) consiste na ativação de todo o coração ou partes do mesmo (só aurículas ou só ventrículos), que introduz uma quebra na sequência correta das contrações do músculo cardíaco e se manifesta no traçado do sinal fisiológico ECG. Para compreender os fenómenos associados à ocorrência de ES é necessário introduzir alguns termos. A pausa compensatória (Figura 9) é o período de tempo que sucede uma ES, quando ele é suficiente para compensar a prematuridade da ES. Isto significa que para haver pausa compensatória, o pequeno intervalo de tempo entre uma batida normal e uma ES que se lhe segue somado ao intervalo de tempo entre essa ES e a batida normal posterior, tem que ser igual a dois intervalos de tempo normais entre batidas (I).




Figura 9 - Representação de uma extra-sístole (seta vermelha) entre dois batimentos normais. Na figura está representada uma situação em que existe pausa compensatória: $\overline{Rs2Re} + \overline{ReRs3} = \overline{Rs3Rs4} + \overline{Rs4Rs5}$ (I).

Existem três mecanismos comuns responsáveis pelo aparecimento de ES (I):

1. **Automaticidade.** No mecanismo de automaticidade, desenvolve-se um novo local de despolarização em tecido não nodal, o que pode conduzir ao aparecimento de uma ES. Quando este mecanismo ocorre frequentemente, pode ser devido a anormalidades eletrolíticas ou isquemia do miocárdio.
2. **Circuito de reentrada.** Este mecanismo consiste no retorno de um impulso a uma zona do músculo cardíaco que foi recentemente ativada pelo mesmo impulso. O fenómeno de reentrada ocorre tipicamente quando tecido de condução lenta (ex.: miocárdio enfartado) se encontra adjacente a tecido normal.
3. **Atividade desencadeada.** Pós-despolarizações desencadeadas por um impulso precedente podem levar a uma ativação prematura se o limiar é atingido, e isto

pode causar uma extra-sístole. As pós-despolarizações podem ocorrer durante a repolarização (pós-despolarização precoce) ou depois de a mesma já estar concluída (pós-despolarização tardia).

Enquanto que os mecanismos 1 e 3 são considerados de anomalias na formação de impulsos, o mecanismo 2 é de anomalias na condução de impulsos [7].

De uma forma genérica e de acordo com as circunstâncias de ocorrência, as extra-sístoles dividem-se em 3 tipos: a ES interpolada (Figura 10-A), a ES prematura (Figura 10-B) e grupos de extra-sístoles (Figura 10-C). A ES interpolada, em vez de ser seguida por uma pausa compensatória é introduzida no meio de dois batimentos normais, de tal forma que se não estivesse presente os intervalos entre os batimentos seriam normais. Na ES prematura, a onda de sinal que a representa sobrepõe-se à onda T precedente. Por fim, a ocorrência de grupos de extra-sístoles consiste, como o próprio nome indica, na sucessão de várias extra-sístoles seguidas e muito pouco separadas no tempo após um batimento normal (I).




Figura 10 - Tipos de extra-sístoles. A - Extra-sístole interpolada; B - Extra-sístole prematura; C - Grupo de extra-sístoles (I).

Quanto ao local de origem, as extra-sístoles são classificadas como auriculares, ventriculares ou nodais. A extra-sístole auricular é um batimento que ocorre mais cedo do que o normal e interrompe brevemente o ritmo cardíaco normal. Este evento causa frequentemente uma sensação de ausência de um batimento seguida de um batimento mais vigoroso. As ESAs têm origem no miocárdio auricular e são comuns em indivíduos saudáveis.

Os impulsos ectópicos¹⁵ das extra-sístoles auriculares podem ou não ser conduzidos para os ventrículos [1], (II). Uma extra-sístole nodal é um batimento prematuro que tem origem no nó AV e leva a uma contração simultânea ou quase simultânea das aurículas e dos ventrículos (III). As extra-sístoles ventriculares serão descritas com maior detalhe na secção 2.10.

2.10 - Extra-Sístoles Ventriculares

Uma extra-sístole ventricular (ESV) é caracterizada pela ocorrência prematura de um complexo QRS que tem uma forma anormal, e duração que de uma forma geral excede a duração de complexos QRS normais. Esta duração anormal geralmente é de mais de 120 milissegundos. A onda T é geralmente larga e apresenta uma deflexão negativa, contrariamente ao que se passa em batimentos normais. O complexo QRS não é precedido por uma onda P prematura mas pode ser precedido por uma P não conduzida que ocorre no instante adequado [7]. Na Figura 11 pode visualizar-se uma representação simples de uma ESV.




Figura 11 - Representação de uma ESV entre batimentos normais. Observa-se claramente que as ESV apresentam uma maior amplitude do pico R, uma maior largura do complexo QRS, uma onda T com polaridade invertida, e ausência de onda P precedente (IV).

O diagnóstico de uma ESV nunca pode ser feito com uma certeza inequívoca a partir de um ECG, uma vez que um batimento supraventricular pode mimetizar manifestações de arritmia ventricular. A transmissão retrógrada¹⁶ para as aurículas a partir de ESV ocorre com bastante frequência, mas normalmente é mascarada pela onda T e complexo QRS distorcidos (Figura 12-B). Se o impulso retrógrado provocar uma recomposição (*reset*) prematura do nó sinusal, a pausa que existirá até ao batimento subsequente não será completamente compensatória. Mais comumente, o nó sinusal e as aurículas não são ativados prematuramente pelo impulso retrógrado, porque ocorrem frequentemente interferências de impulsos na junção AV na forma de colisão entre o impulso retrógrado proveniente da ESV e impulso mais recente proveniente do nó sinusal. Por conseguinte, normalmente após uma ESV ocorre uma pausa compensatória (Figura 12-A). Porém, por vezes uma ESV pode não produzir qualquer pausa e ser interpolada (Figura 10-A e Figura 12-E) [7].

¹⁵ Impulsos deslocalizados temporalmente, relativamente ao ritmo cardíaco normal.

¹⁶ Transmissão de impulsos elétricos cardíacos no sentido oposto daquele que é o sentido normal de condução.




Figura 12 - Extra-sístoles ventriculares (ESV). Os registos de A a D foram gravados do mesmo paciente. (A) Uma ESV tardia resulta na presença de uma pausa compensatória; (B) Uma taxa sinusal mais lenta resulta numa excitação auricular retrógrada - P'; (C) Os eventos são similares aos de (B), mas em C ocorre uma batida de fusão - F - que é fruto de uma taxa sinusal ligeiramente mais alta; (D) O impulso que se propaga retrogradamente para as aurículas reverte a sua direção após um atraso e retorna aos ventrículos, excitando-os. (E) A uma ESV interpolada segue-se um batimento que apresenta um intervalo P-R ligeiramente mais longo do que o normal. Os gráficos mostrados correspondem à derivação II do ECG. Os círculos vermelhos indicam a origem das ESV [7].

Como regra geral, ESV originadas no ventrículo esquerdo apresentam uma morfologia de bloqueio do ramo direito, e ESV originadas no ventrículo direito apresentam uma morfologia de bloqueio do ramo esquerdo [8]. Os ramos aqui retratados são os dois ramos que resultam

da bifurcação do feixe de His (Figura 1). Como já referido anteriormente neste trabalho, o ramo direito transporta impulsos para a contração do ventrículo direito e o ramo esquerdo transporta impulsos para a contração do ventrículo esquerdo. Quando existe um bloqueio do ramo direito (Figura 13-A), não são transportados impulsos para a contração do ventrículo direito pelo circuito normal. Em vez disso, chegam até lá impulsos oriundos do ramo esquerdo através do espalhamento por meio de fibras musculares do miocárdio não especializadas. Isto resulta numa contração retardada do ventrículo direito. Quando existe um bloqueio do ramo esquerdo (Figura 13-B), a situação é homóloga, só que para o lado esquerdo do coração. O resultado final é a contração retardada do ventrículo esquerdo (III).




Figura 13 - Padrões de ECG nos bloqueios de ramo. (A) Bloqueio de ramo direito: É visível a onda R elevada nas derivações III, V1 e V2 e a deflexão negativa da onda S nas derivações I, V5 e V6. É também visível a onda R elevada nas derivações V1 e V2 e a deflexão negativa da onda S nas derivações V5 e V6. (B) Bloqueio do ramo esquerdo: É visível a elevação da onda R nas derivações I, V5 e V6 e a deflexão negativa da onda S nas derivações III, V1 e V2 (I).

Interferências no interior de um ventrículo podem resultar em batidas ventriculares de fusão de impulsos, causadas por ativações simultâneas do ventrículo em dois focos. Um desses focos está relacionado com o impulso supraventricular e o outro está relacionado com uma ESV. A existência ou não de pausa compensatória, excitação auricular retrógrada, um complexo interpolado, complexo de fusão, ou se ocorrem batimentos de eco (Figura 12-D), são questões que se relacionam com o modo de condução dos impulsos pelo nó AV e com o *timing* dos eventos que ocorrem [7].

Existem padrões temporais específicos de ocorrência de ESV, cada um dos quais tem uma designação específica. O termo bigeminismo (Figura 14-A) refere-se a pares de batimentos e indica um batimento normal seguido de um batimento prematuro. O trigeminismo (Figura 14-B) indica um batimento prematuro seguido de dois batimentos normais. O quadrigeminismo indica um batimento prematuro seguido de três batimentos normais. Duas ESV sucessivas são conhecidas como par (*couplet*), enquanto que três ESV sucessivas são designadas por trio

(*triplet*). A ocorrência de três ou mais extra-sístoles sucessivas pode ser sinónimo de ocorrência de taquicardia ventricular. As ESV que ocorrem próximas umas das outras podem ter diferentes morfologias e neste caso são frequentemente designadas multifocais (Figura 15). Mais propriamente, elas devem ser denominadas multiformes, polimórficas ou pleomórficas, porque não é certo que o fenómeno esteja a ser originado por múltiplos focos, podendo tratar-se simplesmente de mudanças na condução de um impulso originário de um só local. As ESV podem ter acoplamento fixo ou variável. Isto é, os intervalos entre o complexo QRS normal e a ESV podem ser relativamente estáveis (aproximadamente iguais) ou variáveis. O acoplamento fixo pode ser causado por reentrada, atividade desencadeada e outros mecanismos. O acoplamento variável pode ser causado por uma parassístole. A parassístole é um tipo de ESV que pode estar associada a uma automaticidade aumentada, ou seja, é causada pela presença de um *pacemaker* adicional que funciona em paralelo com o nó sinusal. Isto na prática traduz-se em intervalos constantes entre ESV, mas com acoplamentos variáveis com os batimentos normais [7], [9]. Geralmente é difícil determinar o mecanismo preciso responsável pelas ESV com base nos intervalos de acoplamento variáveis ou constantes [7].



Figura 14 - Padrões temporais de ocorrência de ESV. (A) Bigeminismo; (B) Trigemínismo. As setas da figura indicam as ESV (I).



Figura 15 - Extra-sístoles ventriculares multiformes. Os complexos QRS extra-sistólicos “normais” para esta onda apresentam uma morfologia de bloqueio de ramo esquerdo (ponta de seta vermelha), e a estes complexos seguem-se outras ESV com diferentes morfologias. A derivação de sinal apresentada é a V1 [7].

2.11 - Relevância Clínica das ESV

O rastreio das extra-sístoles ventriculares é tipicamente uma tarefa manual que envolve a análise da morfologia dos batimentos cardíacos, da duração do complexo QRS e das variações

nos intervalos R-R, usando registros de ECG de longa duração. Esta tarefa consome bastante tempo [10].

A prevalência de ESV aumenta com a idade. Elas estão associadas ao gênero masculino e a uma baixa concentração de potássio no soro sanguíneo. As ESV são mais frequentes durante a manhã em pacientes que tenham sofrido enfarte do miocárdio, mas esta variação circadiana¹⁷ é ausente em pacientes com grave disfunção do ventrículo esquerdo. Sintomas de palpitações ou desconforto no pescoço ou no peito podem estar presentes, devido a uma força de contração das batidas que sucedem às ESV maior do que o normal, ou à sensação de que o coração parou durante a longa pausa que se segue à ESV. Cadeias longas de ESV em pacientes com doença cardíaca podem produzir angina, hipotensão, ou falha cardíaca. ESV interpoladas frequentes representam na realidade um aumento da frequência cardíaca para o dobro e podem comprometer o equilíbrio hemodinâmico do paciente. Em alguns pacientes, ESV isoladas mas frequentes podem causar falha cardíaca, que é revertida quando o paciente é submetido a ablação (remoção dos focos de arritmias através de um catéter). Atividades que aumentam a frequência cardíaca podem reduzir o número de ESV ou então a sensibilidade do paciente à ocorrência das mesmas. O exercício físico pode aumentar o número de ESV em alguns pacientes. As ESV podem ser desconfortáveis em pacientes que apresentam insuficiência aórtica, devido ao grande volume sistólico (volume de sangue que cada ventrículo expelle após a contração). O sono está geralmente associado com uma diminuição da frequência de arritmias ventriculares, mas alguns pacientes podem experimentar um aumento das mesmas [7].

As ESV ocorrem com associação a vários estímulos e podem ser produzidas por estimulação mecânica direta, elétrica ou química do miocárdio. Frequentemente, elas são detetadas em pacientes com falsos tendões do ventrículo esquerdo, durante infecções, em miocárdio isquêmico ou inflamado, e durante a hipoxia¹⁸, anestesia ou cirurgia. As ESV podem ser provocadas por vários medicamentos, desequilíbrios eletrolíticos, estados de tensão (stress emocional), falta de horas de sono, extensão do miocárdio, e uso excessivo de tabaco, cafeína, álcool ou drogas pesadas. A estimulação levada a cabo pelo sistema nervoso produz também efeitos profundos na frequência cardíaca e pode produzir ou suprimir ESV [1], [7].

Por meio da examinação física de um paciente pode ser detetada a presença de uma batida prematura seguida de uma pausa que é mais longa do que o normal. Isto porque uma pausa compensatória total pode ser distinguida de uma que não é completa, uma vez que a primeira não altera o *timing* do ritmo base [7].

A relevância das ESV depende do quadro clínico do paciente em questão. Na ausência de patologia cardíaca subjacente, a presença de ESV geralmente não tem impacto na longevidade ou limitação de atividade. Por isso, neste caso as drogas antiarrítmicas não são recomendadas e os pacientes devem ser tranquilizados em relação à ocorrência de ESV [7].

¹⁷ Adjetivo relativo a fenômenos regulados pelo “relógio biológico”, o qual afeta o ritmo diário de muitos processos fisiológicos.

¹⁸ Estado de baixo teor de oxigênio.

Existe um estudo que reporta que a ocorrência de extra-sístoles multifocais é geralmente acompanhada de uma patologia miocárdica grave [11]. Em outro estudo, é demonstrado que é muito importante seguir a ocorrência de ESV em pacientes após enfarte agudo do miocárdio, uma vez que certos eventos que possam ocorrer podem ser presságios de arritmias severas, nomeadamente taquicardia e/ou fibrilação ventricular. Esses eventos são: ESV multiformes, ESV com acoplamento variável, o fenômeno de sobreposição da onda R na onda T do batimento precedente, o bigeminismo, e a ocorrência de ESV em número maior ou igual a cinco por minuto [12].

Mais recentemente foi demonstrado que em pacientes com enfarte agudo do miocárdio, as ESV que outrora eram consideradas um presságio de fibrilação ventricular, como as que ocorrem próximas à onda T precedente, mais que cinco ou seis por minuto, bigeminismo ou complexos multiformes, ou as que ocorrem em salvas de duas, três ou mais, não ocorrem em cerca de 50% de pacientes que desenvolvem fibrilação ventricular. Além disso, a fibrilação ventricular também não se desenvolve em 50% dos pacientes que apresentam aqueles tipos de ESV. Por conseguinte, estas ESV não são particularmente úteis no prognóstico [7].

2.12 - Resumo

Neste capítulo, inicialmente foi feita uma descrição do funcionamento do sistema de condução elétrica do coração, da morfologia do sinal ECG, como é feita a sua recolha e como cada um dos seus componentes se relaciona com eventos de condução específicos. Esta etapa teve o intuito de fornecer ao leitor um enquadramento no tema em estudo.

Posteriormente, foram descritos os tipos de ESV existentes e as suas formas de manifestação nos sinais ECG. Desta forma, deram-se a conhecer os tipos de morfologias que as ESV podem assumir, o que é importante para depois serem definidas estratégias de deteção deste tipo de arritmias.

Por fim, teceram-se considerações acerca da relevância clínica da ocorrência de ESV, que demonstram a importância da monitorização deste tipo de fenómenos.

Capítulo 3

Reconhecimento de padrões em sinais ECG

3.1 - Introdução

Neste capítulo está apresentado um estudo do estado da arte relativo a técnicas de processamento de sinal ECG, bem como de algoritmos de classificação aplicados à detecção de arritmias cardíacas. Algumas das técnicas aqui apresentadas serão utilizadas no desenvolvimento do projeto.

3.2 - Remoção de ruído

Um sistema geral robusto capaz de distinguir frequências cardíacas transitórias e extrair características morfológicas de batimentos cardíacos em ECG de longa duração inclui sempre uma etapa de pré-processamento [13].

De uma forma geral, o objetivo do pré-processamento é melhorar a qualidade do sinal ECG, tendo em vista uma maior precisão em análises e medições. Os ruídos podem perturbar os sinais ECG de tal forma que as medições a partir de sinais originais não sejam confiáveis. Os principais tipos de ruído são: flutuação da linha de base - ruído de baixa frequência causado pela respiração e movimentos corporais; ruído aleatório de frequência superior à maior frequência da banda de interesse do sinal ECG (Figura 8) - causado por interferências da rede de alimentação elétrica (50 ou 60 Hz) e pela atividade muscular. Também se podem verificar alterações aleatórias na amplitude do sinal causadas por contacto pobre dos eléctrodos com a pele e por movimentos corporais [13].

Flutuações de linha de base. As flutuações da linha de base representam uma atividade de muito baixa frequência no ECG, o que pode interferir com a análise do sinal. As consequências deste fenómeno são interpretações clínicas imprecisas e enganosas. As mudanças ST-T no ECG são medidas relativamente à linha isoeletrica. Quando estão presentes flutuações da linha de base não existe uma linha isoeletrica bem definida, o que torna a análise ST imprecisa. Este fenómeno pode resultar de várias fontes de ruído tais como transpiração, respiração, movimentos corporais e contacto pobre dos eléctrodos com a pele. O seu conteúdo espectral está geralmente abaixo de 1 Hz, mas pode conter frequências mais altas durante um exercício físico vigoroso [6], [13]. O *design* de um filtro passa-alto linear e invariante no tempo para a eliminação das oscilações envolve várias questões, sendo as mais cruciais as escolhas da frequência de corte e da resposta de fase do filtro. Tem que se ter em consideração que é impensável perder informação clínica contida no sinal ECG. Desta forma, é necessário encontrar o componente do sinal ECG ao qual está associada a menor

frequência. O que define este componente é a frequência cardíaca mais baixa possível, uma vez que a forma de onda PQRST está associada a maiores frequências. Durante a bradicardia, a frequência cardíaca pode cair para valores de aproximadamente 40 batimentos por minuto, o que corresponde a uma frequência de $40/60 = 0.67$ Hz. Há também que ter em consideração que a frequência cardíaca não é perfeitamente regular, podendo flutuar de um batimento cardíaco para o seguinte. Portanto, para o filtro passa-alto deverá ser utilizada uma frequência ligeiramente menor do que 0.67 Hz, tal como 0.5 Hz [6]. Um filtro deste tipo também remove a componente DC do sinal, a qual está associada à frequência 0 Hz. A outra questão crucial do *design* está relacionada com as propriedades de fase do filtro e consequentemente com a sua estrutura. A filtragem de fase linear é altamente desejável, de modo a prevenir a distorção de fase, a qual pode alterar várias propriedades das ondas do ciclo cardíaco tais como a duração do complexo QRS, o nível do segmento ST-T, ou a terminação da onda T. Os filtros FIR podem ter uma resposta de fase linear, com uma resposta ao impulso simétrica ou antissimétrica. A desvantagem dos filtros FIR é que a sua implementação requer ordens mais elevadas do que os filtros IIR [6].

Ruído de alta frequência. Como o limite superior da banda de frequências de interesse do sinal ECG é 40 Hz (Figura 8), um filtro passa-baixo com uma frequência de corte igual a esse valor ou ligeiramente superior poderá eliminar desde logo ruídos provenientes da rede de alimentação elétrica e também de sinais eletromiográficos sem comprometer o sinal de interesse.

Outros métodos de remoção de ruído de alta frequência baseiam-se na transformada de *wavelet*. Esta transformada utiliza famílias de funções com morfologia semelhante ao sinal ECG. Utilizando uma família de funções, o sinal ECG é decomposto a diferentes níveis em duas componentes (aproximações e detalhes) de acordo com um critério de correspondência de morfologia. Os detalhes constituem a componente de alta frequência a descartar [14], [15].

3.3 - Detecção de complexos QRS

A tarefa de um detetor de complexos QRS é detetar estas estruturas para cada batimento cardíaco, gerando um ponto de referência estável em cada deteção. O ponto de referência e o seu posicionamento devem ser robustos e insensíveis a eventuais variabilidades morfológicas subtis no complexo QRS [13]. A Figura 16 representa a estrutura básica de um detetor de complexos QRS.



Figura 16 - Estrutura de um detetor de complexos QRS [16].

Entre os algoritmos de deteção de complexos QRS disponíveis na literatura, o mais popular é o algoritmo proposto por Pan e Tompkins em 1985 [17], [18].

O processamento do sinal ECG no algoritmo de Pan-Tompkins baseia-se na aplicação sequencial de um filtro passa-banda, derivada, quadrado e integração de janela móvel. O resultado final é um sinal em que estão apenas presentes os picos de energia do complexo QRS [17], [18]. Este algoritmo de detecção será explicado em pormenor na secção 4.2.3 uma vez que o detetor de complexos QRS construído neste projeto é baseado no algoritmo referido.

Após o processamento de sinal efetuado num detetor de complexos QRS, aplica-se uma regra de decisão ao sinal resultante, que consiste em testar cada pico no sentido de determinar se efetivamente corresponde a um complexo QRS. O critério de decisão pode ser implementado como um simples limiar de amplitude, mas geralmente inclui testes adicionais, como por exemplo a duração da forma de onda, de forma a assegurar uma melhor imunidade contra vários tipos de ruído. O limiar é geralmente adaptado às amplitudes das formas de ondas mais recentes para que se possam acompanhar mudanças graduais de amplitude [6].

Existem abordagens mais simples que o algoritmo de Pan-Tompkins para detetar picos QRS. Em alguns algoritmos simples, o processamento baseia-se apenas na aplicação da derivada do sinal, utilizando assim o declive acentuado do complexo QRS para a sua detecção. Alguns algoritmos utilizam também a segunda derivada, fazendo uma combinação linear das magnitudes da primeira e segunda derivada. O critério de detecção também aqui baseia-se na comparação de características com um limiar de detecção, o qual geralmente é adaptativo [16].

A transformada de *wavelet* é também um método bastante utilizado na detecção de complexos QRS, além de ser utilizada na eliminação de ruído de alta frequência, como já foi referido na secção 3.2. Cada família de funções *wavelet* apresenta várias funções filhas, que se relacionam com a função mãe através de coeficientes de posição e de escala. Utilizando uma família de funções, os complexos QRS são identificados ao serem associados aos coeficientes da função que representa a sua morfologia [16], [18].

Existem ainda muitos mais métodos de detecção de complexos QRS, baseados em redes neuronais, modelos de Markov, morfologia matemática, algoritmos genéticos, transformada de Hilbert [16].

3.4 - Algoritmia de detecção e classificação

A função de um algoritmo de classificação é identificar padrões, sendo que um padrão é uma individualidade representada por um conjunto particular de características do sinal a analisar. Numa primeira análise, a tarefa de reconhecer padrões através da avaliação de diferentes características pode não parecer complicada, mas por vezes é. Considere-se uma analogia, em que um especialista em cardiologia realiza uma classificação de padrões baseada na visualização da forma de onda do sinal ECG, o que implica uma certa experiência. Cada tipo de ECG patológico exhibe um padrão de onda característico que se repete de uma forma mais ou menos regular ao longo do tempo. Os cardiologistas têm a função de analisar os ECG e associá-los a diferentes estados fisiológicos do coração. A situação é a seguinte [19]:

- Existe um conjunto de classes (estados), nas quais pode ser encontrada uma certa entidade estudada. No caso do coração estas entidades correspondem a diferentes arritmias.
- A cada classe está associado um certo conjunto de representações (sinais, imagens, etc.) - os padrões. Neste caso os ECG são os padrões¹⁹.
- De cada padrão pode ser extraída informação que o caracteriza - as características. No caso do ECG, as características estão relacionadas com medições de parâmetros das ondas, como por exemplo amplitudes e durações. Uma característica pode ser, por exemplo, a razão entre as amplitudes das ondas R e Q. Por razões de simplicidade, é desejável a utilização de um número de características que seja o mais reduzido possível.

No reconhecimento de padrões é necessário definir os espaços de características, padrões e classes. Um sistema de reconhecimento de padrões que mimetize as capacidades de um cardiologista, quando confrontado com um vetor de características terá que inferir acerca de uma condição cardíaca (diagnóstico) a partir dele. Daqui podem surgir dois cenários [19]:

1. Características de padrões que pertencem a diferentes classes são semelhantes;
2. Um padrão particular esteja presente em classes distintas.

O primeiro cenário pode ser resolvido através da adição de novas características discriminativas de padrões. Por sua vez, o segundo cenário é intrínseco ao método e, na realidade, os melhores especialistas em eletrocardiografia têm um limite superior de eficácia para o seu desempenho. Por consequência, um sistema de reconhecimento de padrões não pode garantir erro nulo, independentemente do tipo de abordagem utilizada. Normalmente, atinge-se um grau de satisfação quando o erro de desempenho é comparável ao verificado para os especialistas humanos [19].

3.5 - Classificação não supervisionada

Este tipo de classificação de batimentos cardíacos consiste na formação de grupos (*clusters*) distintos de objetos de acordo com as suas características, sem a presença de um conhecimento prévio acerca do tipo de padrão a classificar [19]. Uma abordagem para a extração de características é a derivação de características heurísticas que, por exemplo, descrevam a área, polaridade e declives das ondas dos sinais ECG. Outra abordagem, sendo esta mais robusta, consiste em fazer uso de coeficientes resultantes da correlação de cada batimento cardíaco com um conjunto de funções de base ortonormal predefinidas ou um conjunto de modelos de complexos QRS. O *clustering* é efetuado a partir da avaliação das características extraídas e, na sua forma mais simples pode ser utilizado para destacar batimentos cardíacos cuja morfologia difere da morfologia predominante, a qual

¹⁹ Um conjunto de padrões aplicado ao *design* de um sistema de reconhecimento de padrões denomina-se *training set*

normalmente corresponde ao ritmo sinusal normal. Posteriormente, batimentos cardíacos pertencentes ao *cluster* do ritmo normal podem ser submetidos a uma média conjunta global ou a uma análise da variabilidade da frequência cardíaca. Noutras situações, justifica-se um estudo de todos os *clusters* de batimentos cardíacos. Uma vez que o *clustering* não fornece um rótulo com um significado fisiológico a cada um dos diferentes batimentos cardíacos, pode ser necessária a realização de uma classificação de batimentos de acordo com a sua origem cardíaca [6].

Um vetor de características descreve uma morfologia de onda específica e, possivelmente, também propriedades rítmicas do batimento cardíaco. Na sua forma mais simples, o vetor de características do batimento i , p_i contém amostras do domínio do tempo de complexos QRS, e é frequentemente utilizado em combinação com o coeficiente de correlação cruzada ρ_{il} como uma medida de similaridade de padrões,

$$\rho_{il} = \frac{p_i^T \mu_l}{\|p_i\|_2 \|\mu_l\|_2} \quad 3.1$$

onde $\|\cdot\|_2$ denota a norma euclidiana. O vetor coluna μ_l define a média do cluster l (e é comumente designado como batimento modelo). As amostras de ECG do batimento corrente são filtradas previamente ao *clustering*, reduzindo a influência de oscilações de linha de base e de ruído proveniente de sinais eletromiográficos e outras interferências. Uma abordagem simples para o *clustering* é dada pela atribuição do batimento cardíaco i ao *cluster* para o qual se obtém um maior coeficiente de correlação, desde que este exceda um determinado limiar. Se esse limiar não for atingido, um novo *cluster* é criado. Abordagens mais complexas e recentes para o *clustering* consistem no uso de redes neuronais artificiais [6]. A Figura 17 mostra um exemplo de *clustering* de um conjunto de batimentos cardíacos onde estão presentes duas morfologias distintas.

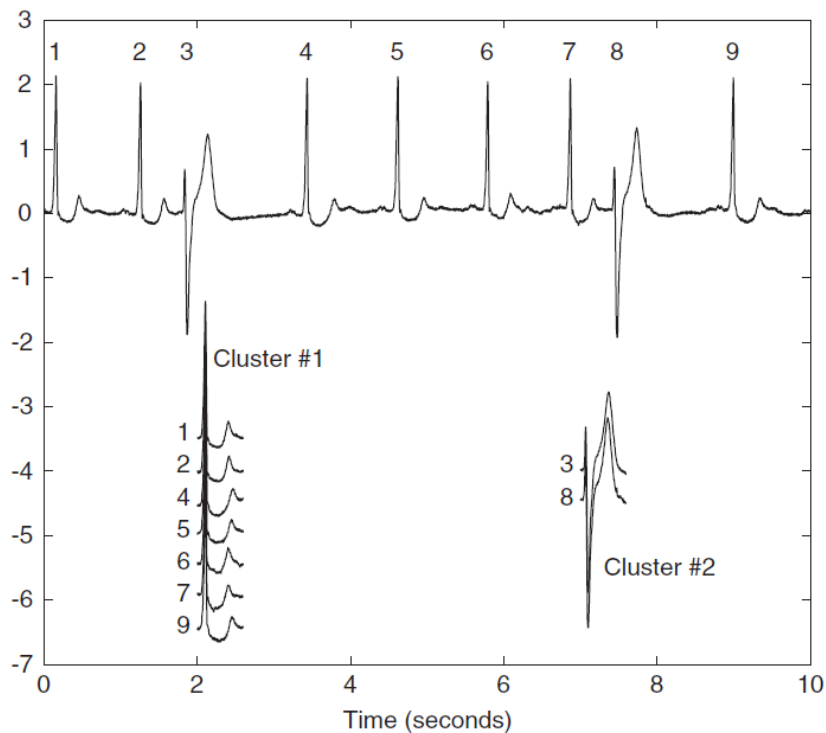


Figura 17 - Agrupamento (*clustering*) de um ECG que contém duas diferentes morfologias de batimentos cardíacos - 7 batimentos normais e 2 batimentos ectópicos. Os dois batimentos ectópicos são duas ESV [6].

Existem diversos estudos na literatura que utilizam a classificação não supervisionada para detecção de condições cardíacas anormais [10], [20], [21]. Também estão descritas abordagens que combinam este método com a classificação supervisionada [22].

Um dos estudos existentes propõe um algoritmo de detecção de ESV e utiliza métodos de extração e seleção de características simples e intuitivos [10]. Este estudo conduziu a resultados bastante razoáveis, por isso descrever-se-á brevemente o método. Neste estudo, a duração do complexo QRS não foi incluída para evitar a necessidade de detetar esses pontos de referência. Após o pré-processamento dos sinais de entrada e segmentação de batimentos cardíacos foram então extraídas as características de cada um deles: morfologia, dada por amostras de amplitude; duração do intervalo RR; polaridade, definida como a razão entre o valor máximo e o valor mínimo de um batimento cardíaco, a qual é influenciada pelas direções das onda R e T. O número de amostras de amplitude foi reduzido através de um método de amostragem não uniforme. Seguidamente, foi aplicado um passo de correspondência de morfologia, baseado num método denominado DWT (*Discrete Wavelet Transform*), que constitui a medida de similaridade utilizada nos algoritmos de *clustering*. A DWT é uma técnica de correspondência de padrões que estica o eixo temporal de dois batimentos cardíacos em análise de uma forma não linear e fornece uma medida de similaridade quantitativa a partir da matriz de distâncias cumulativas. Finalizada a extração das características, foi executado o primeiro passo de *clustering*, que consistiu em encontrar um conjunto inicial de *clusters* através do algoritmo *K-means*. Os batimentos foram classificados de acordo com o *cluster* mais próximo, tendo também que obedecer a limites mínimos de similaridade de atributos, caso contrário era criado um novo *cluster*. Depois de ter sido encontrada uma partição inicial estável, foi realizado um *clustering* hierárquico

aglomerativo para agrupar *clusters* similares. A cada iteração era calculada a similaridade entre centróides de *clusters* e se os critérios mínimos de similaridade eram preenchidos, os *clusters* eram fundidos. Este processo foi repetido até que não se pudessem fundir mais *clusters*. Uma vez encontrada a partição final de *clusters*, os batimentos cardíacos de cada *cluster* foram identificados no conjunto inicial de batimentos cardíacos. Depois, os batimentos cardíacos no sinal de entrada foram classificados de acordo com os resultados do *clustering*, e o método acaba [10].

O algoritmo proposto neste estudo foi validado recorrendo a 32 sinais da *MIT-BIH Arrhythmia Database*, que é uma base de dados anotada e utilizada por bastantes investigadores. Esta base de dados consiste em 48 sinais ECG amostrados a 360 Hz, incluindo cada um deles dados de duas derivações. Cada um dos sinais tem uma duração aproximada de 30 minutos (V). Esta base de dados será abordada com maior detalhe na secção 4.2.1. Na Tabela 1 é apresentada uma média das medidas de eficácia verificadas para cada um dos 32 sinais.

Tabela 1 - Resultados das experiências, utilizando batimentos normais e ESV. *SE* - Sensibilidade; *SP* - Especificidade; *P+* - Precisão [10].

	SE (%)	SP (%)	P+ (%)
Média de 32 sinais	98,36	99,90	99,83

Como se pode verificar na Tabela 1, o algoritmo proposto tem um desempenho bastante razoável. O *clustering* foi realizado de uma forma precisa sem informação prévia do número de *clusters* e sem um conjunto de dados de treino [10].

3.6 - Classificação supervisionada

Na secção 3.4 foi referido que um conjunto de padrões aplicado ao *design* de um sistema de reconhecimento de padrões constituía um *training set* [19]. Esse conjunto de padrões, os quais se encontram devidamente associados a uma classe, fornece o perfil da distribuição das classes no espaço de características. Essa informação permite treinar um algoritmo para classificar novos objetos com que seja posteriormente confrontado. Um sistema de reconhecimento de padrões que utiliza essa informação para treino é um sistema de classificação supervisionada [19].

Existe uma grande diversidade de estudos que aplicam diversos algoritmos de classificação supervisionada à deteção de arritmias cardíacas. Em primeiro lugar, referenciar-se-á um estudo em que é utilizado o algoritmo de classificação K^{th} *Nearest-Neighbors Rule* (KNN) para classificar batimentos cardíacos em normais ou ESV [23]. O algoritmo KNN é um algoritmo de classificação simples e encontra-se descrito na secção 4.2.6. Para este estudo, foram utilizados todos os dados da *MIT-BIH Arrhythmia Database* e os batimentos arritmicos não pertencentes à classe ESV foram incluídos no grupo dos batimentos normais. Para cada ciclo cardíaco, inicialmente foi determinada a largura do complexo QRS com base na análise das duas derivações de sinal. Depois, foram extraídos parâmetros de cada uma das duas derivações, sendo alguns deles: a amplitude do pico positivo máximo; a amplitude do pico

negativo máximo; a área como a soma de valores absolutos no intervalo do batimento; a área de valores positivos no mesmo intervalo; a área de valores negativos no mesmo intervalo; o número de amostras com amplitude maior que 70% da amplitude do pico de maior amplitude [23].

Apesar de no estudo referenciado terem sido extraídas 26 características no total, as referidas acima são as mais relevantes, motivo pelo qual foram utilizadas na metodologia do presente trabalho (ver secção 4.2.5).

No estudo que está a ser descrito, a partir das 26 características extraídas testou-se o algoritmo de classificação KNN para cada paciente, utilizando *training sets locais*, em que eram incluídos alguns batimentos cardíacos do paciente a testar, e *training sets globais*, nos quais não eram incluídos batimentos cardíacos do paciente a testar. O desempenho da classificação foi avaliado em termos de sensibilidade (SE) e especificidade (SP) do algoritmo mediante a utilização dos dois tipos de *training set*. Os resultados estão na Tabela 2 [23].

Tabela 2 - Especificidade (SP) e Sensibilidade (SE) obtidas pelo algoritmo KNN com conjuntos de dados locais e globais [23].

	K th Nearest Neighbour	
	SE (%)	SP (%)
Training set global	81,6	78,3
Training set local	97,3	97,7

Em outro estudo da literatura [24], foram comparadas 7 abordagens para agrupamento e classificação de batimentos cardíacos em normais ou ESV. Os algoritmos foram testados com a *MIT-BIH Arrhythmia Database* e uma outra base de dados - *AHA Database (VI)*.

As abordagens utilizadas neste estudo foram diversas. Utilizaram-se algoritmos simples como árvores de decisão - *Rule-Based Decision Tree (RBDT)* e *Rule-Based Decision Tree clustering Based on Fuzzy Intervals (fuzzy RBDT)* - e algoritmos mais complexos como redes neuronais - *Self-organizing map ANN (SOM)*, *Group of Adaptive Models ANN (GAME NN)*, *Back Propagation ANN (BP NN)*, *Radial Basis Function ANN (RBF)* - e *Support Vector Machines (SVM)* [24].

De entre as 7 abordagens utilizadas neste estudo, as SVM merecem um destaque especial porque serão utilizadas neste projeto. As SVM são sistemas de aprendizagem que são treinados por um algoritmo baseado na teoria de otimização, e têm uma relação próxima com os algoritmos baseados em redes neuronais. Este método encontra um hiperplano de separação no espaço das características que mantém o erro empírico pequeno enquanto é maximizada a margem entre o hiperplano e as instâncias próximas a ele. Os vetores de entrada são mapeados no espaço de características através de uma função, o *kernel*, que pode ser linear, polinomial ou uma *Radial Basis Function (RBF)* [24]. Este algoritmo encontra-se descrito com maior detalhe na secção 4.2.6.

Para comparação das 7 abordagens referidas acima, foram extraídos 13 parâmetros dos batimentos cardíacos e cada uma das duas bases de dados utilizada neste estudo foi dividida em conjuntos de treino e de teste (*training set* e *test set*). O *training set* consistiu em números iguais de batimentos normais (N) e ESV. Os batimentos que estavam anotados como sendo de outra arritmia que não ESV foram associados aos normais. Para cada uma das bases de dados foram selecionados aleatoriamente 20 N e 20 ESV de cada sinal para integrar o *training set*, se disponíveis. O *test set* consistiu no resto dos batimentos cardíacos de cada uma das duas bases de dados. Os resultados da classificação estão apresentados na Tabela 3. O *kernel* utilizado no algoritmo SVM foi uma RBF [24]. Como se pode verificar, os resultados são mutuamente comparáveis, sendo que nenhum classificador supera todos os outros.

Tabela 3 - Resultados de desempenho da classificação, obtidos com os diferentes métodos para as duas bases de dados (MIT e AHA) [24].

Método	MIT - SE (%)	MIT - SP (%)	AHA - SE (%)	AHA - SP (%)
RBDT	96,63	92,64	85,79	74,35
<i>fuzzy</i> RBDT	95,78	91,31	87,81	79,21
BP NN	93,12	76,13	86,86	77,06
GAME NN	41,59	94,04	49,57	95,41
RBF	89,88	75,94	72,28	87,16
SOM	97,95	35,41	97,00	35,21
SVM	94,10	94,01	93,80	91,47

O algoritmo SVM é muito referenciado na literatura para classificação de batimentos cardíacos. Um outro exemplo desta utilização de SVM está demonstrado num outro estudo [25], cujo objetivo consistia em distinguir três tipos de batimentos cardíacos: normais (N), extra-sístoles auriculares (ESA) e ESV. Para esse fim, utilizaram-se 6 sinais da *MIT-BIH Arrhythmia database* contendo batimentos cardíacos suficientes de cada tipo considerado. Foram utilizadas as anotações da base de dados como pontos de referência para que se pudesse evitar a detecção de complexos QRS, e portanto segmentaram-se de imediato os batimentos cardíacos para extrair características. A extração de características foi feita decompondo cada batimento cardíaco por meio da utilização da família de funções *wavelet Daubechies 4 (DB4)*. Foi utilizada a componente de mais baixa frequência para a extração de características, uma vez que a componente de maior frequência corresponde geralmente a ruído. Com o efeito de *down-sampling*, consideraram-se 4 níveis de DB4, de forma que a sequência de amostras de cada batimento cardíaco foi reduzida para 21, que são os coeficientes *wavelet* das componentes de mais baixa frequência. A Figura 18 mostra uma representação de um conjunto de batimentos cardíacos ao lado de uma representação dos respectivos coeficientes *wavelet* [25].




Figura 18 - Batimentos cardíacos normais (à esquerda) e coeficientes *wavelet* (à direita) [25].

Neste estudo, os conjuntos de dados de treino e teste foram selecionados aleatoriamente a partir do conjunto de dados global, cada um contendo quantidades iguais dos 3 tipos de batimentos cardíacos. Foi aplicado o método *Principal Component Analysis* (descrito na secção 4.2.7), que fornece uma matriz de transformação das características que é utilizada para reduzir a sua dimensão. Os tamanhos escolhidos para o vetor de características foram 2, 3 e 4. Inicialmente, o conjunto de dados foi categorizado em batimentos normais e batimentos anormais, em que os conjuntos de treino e teste foram selecionados como descrito acima. A classificação foi realizada com a utilização de 2, 3 e 4 características como *input* para o algoritmo SVM, e os *kernels* utilizados para o mapeamento foram RBFs. Um procedimento similar foi também aplicado ao conjunto de dados, em que a classificação foi feita em ESV e não ESV e em ESA e não ESA. A Figura 19 representa o desempenho do classificador nas diferentes configurações dos testes. Os resultados demonstram que a utilização de um vetor de características com dimensão menor não degrada o desempenho do classificador [25].




Figura 19 - Desempenho do classificador para os 6 tipos de classificação. N (normal e anormal), V (ESV e não ESV), A (ESA e não ESA). A representação consiste em diagramas de caixa, em que as linhas representam a média e os quartis superior e inferior. Os números à frente da letra indicam a dimensão do vetor de características utilizado na classificação [25].

Em um outro estudo, foi comparado o desempenho de SVM, redes neuronais, e um outro algoritmo - ANFIS (*Adaptive-Network-Based Fuzzy Interface System*) - na detecção de ESV. Nesse estudo foi utilizado o algoritmo de Pan-Tompkins [17], [18] para detetar complexos QRS e utilizaram-se dados de 33 dos 48 registos da *MIT-BIH Arrhythmia Database*. Os batimentos cardíacos que correspondiam a outras arritmias que não as ESV foram associados aos batimentos normais. Foram selecionadas 14 características baseadas em parâmetros temporais, morfologia e limiares de amplitude. A dimensão das características foi reduzida recorrendo a LDA (*Linear Discriminant Analysis*) e PCA (*Principal Component Analysis*), verificando-se que os resultados de precisão obtidos com o método LDA foram muito superiores aos obtidos com PCA. Os resultados de classificação foram bastante satisfatórios, com as redes neuronais a terem a maior taxa de sucesso (99,89%), seguidas de SVM (97,54%) e por último, o algoritmo ANFIS (94,65%). Porém, foram utilizadas muito mais instâncias no treino das redes neuronais do que no treino de SVM e ANFIS [26].

Em um estudo mais recente, é feita uma combinação de SVM com um algoritmo genético, e é também proposto um novo classificador SVM - ESVM (*Emphatic SVM*) [27].

3.7 - Resumo

Neste capítulo foi apresentada uma revisão da literatura relativa às estratégias de processamento de sinal ECG, desde o pré-processamento até à detecção de ESV, englobando também as estratégias de detecção de complexos QRS, cujo papel é muito importante. Os estudos que utilizam métodos que serão empregues neste projeto foram descritos em maior pormenor.

Em suma, de acordo com os estudos reportados na literatura, verifica-se que os trabalhos existentes na área são relativamente recentes e que são diversos os algoritmos aplicados para detecção de ESV, com uma predominância evidente de redes neuronais e SVM.

Para extração de características de batimentos cardíacos, verifica-se que em muitos casos utilizam-se medições de parâmetros a partir de pontos de referência, e em alguns casos é utilizada a transformada de *wavelet*.

Relativamente aos sinais utilizados para validação de algoritmos, verifica-se que a *MIT-BIH Arrhythmia Database* é uma base de dados anotada que é utilizada de uma forma generalizada em todos os estudos.

Capítulo 4

Deteção automática de ESV

4.1 - Introdução

Este capítulo representa o cerne desta dissertação e reporta todas as informações relativas ao trabalho experimental associado a este projeto. Na secção 4.2 são descritos os procedimentos efetuados e as técnicas utilizadas e na secção 4.3 são apresentados os resultados obtidos.

4.2 - Metodologia

Inicialmente, descreve-se a base de dados utilizada para teste dos algoritmos construídos, a *MIT-BIH Arrhythmia Database*, que foi selecionada devido à sua utilização generalizada em estudos reportados na literatura. Os dois passos seguintes do trabalho consistem na construção de um algoritmo detetor de complexos QRS e, posteriormente, um primeiro detetor de ESV baseado em apenas um parâmetro do ECG. Seguidamente, extraem-se diversas características de ciclos cardíacos do ECG e aplicam-se métodos de redução da dimensão das mesmas. Numa última etapa são aplicados dois algoritmos de classificação (KNN e SVM) aos vetores de características reduzidos.

4.2.1 - Base de dados

Os sinais utilizados neste trabalho são provenientes da base de dados *MIT-BIH Arrhythmia Database* (V). Esta base de dados é de longe a mais utilizada pelos investigadores e é inclusive utilizada em todos os estudos referidos no estado da arte, como já referido na secção 3.5. A base de dados é composta por 48 sinais, sendo que cada um deles tem a duração de 30 minutos e inclui duas derivações - a derivação II e uma das derivações V1, V2, V4 ou V5. A frequência de amostragem é 360 Hz e a resolução é de 0.005 mV. As anotações de todos os batimentos cardíacos da base de dados foram efetuadas por dois cardiologistas. Para este trabalho foram selecionados 5 sinais da base de dados e utilizou-se apenas a derivação II de cada sinal. O critério de seleção dos sinais baseou-se na maximização da taxa de ocorrência de batimentos normais e ESV em relação a qualquer outro tipo de batimento cardíaco arritmico. Na Tabela 4 encontra-se uma caracterização de cada um dos sinais utilizados.

Tabela 4 - Sinais utilizados no presente trabalho. N - batimento normal; V - ESV.

Sinal	Total de batimentos cardíacos	N	V	Outros
mit119	1987	1543	444	-
mit213	3251	2641	220	390
mit215	3363	3195	164	4
mit223	2605	2029	473	103
mit233	3079	2230	831	18

Na Tabela 4 verifica-se que os sinais utilizados apresentam uma certa variabilidade de frequências cardíacas, uma vez que o total de batimentos cardíacos incluídos apresenta alguma variabilidade entre os cinco sinais e é sabido que a duração da gravação é a mesma em todos os casos.

A Figura 20 ilustra algumas das morfologias de ESV encontradas nos sinais seleccionados.




Figura 20 - Algumas das morfologias de ESV presentes nos sinais. (A) ESV do sinal mit119; (B) ESV do sinal mit213; (C) ESV do sinal mit223; (D) ESV do sinal mit233. Todos os 4 ciclos cardíacos da figura estão aproximadamente à mesma escala.

Apesar de na figura acima estarem presentes apenas quatro ciclos cardíacos, evidenciam-se desde já as diversas morfologias de ESV existentes.

4.2.2 - Pré-processamento

O pré-processamento dos sinais consistiu na aplicação sequencial de um filtro passa-alto e de um filtro passa-baixo. As frequências de corte utilizadas para os filtros foram 0.5 e 40.5 Hz, respetivamente, e foram escolhidas com base na análise do espectro de frequências do sinal ECG (ver Figura 8). Os filtros são de tipologia FIR baseados no método da janela. Neste caso foi utilizada uma janela de *Hamming*. O método de filtragem utilizado foi a filtragem de fase 0. Este tipo de filtragem consiste no processamento dos dados duas vezes, isto é, depois de uma filtragem normal o sinal resultante é invertido e filtrado mais uma vez e invertido uma outra vez no final. As características deste tipo de filtragem são: distorção de fase 0; minimização de transientes de inicialização, preservando-se assim as condições iniciais dos sinais; resposta em magnitude que é o quadrado da resposta em magnitude da filtragem convencional; uma ordem que é o dobro da ordem do filtro especificado. A ordem especificada para os filtros é 1000, e foi escolhida com base em testes de diferentes ordens para o filtro passa-alto, utilizando a filtragem de fase 0 (ver Figura 21). Para manter a homologia no processamento, utilizou-se a mesma ordem para o filtro passa-baixo. A ordem 1000 corresponde à especificação das características dos filtros (1001 coeficientes), mas como a filtragem é de fase 0, a ordem real dos filtros é 2000. A resposta em magnitude e em fase da combinação dos dois filtros está representada na Figura 22.

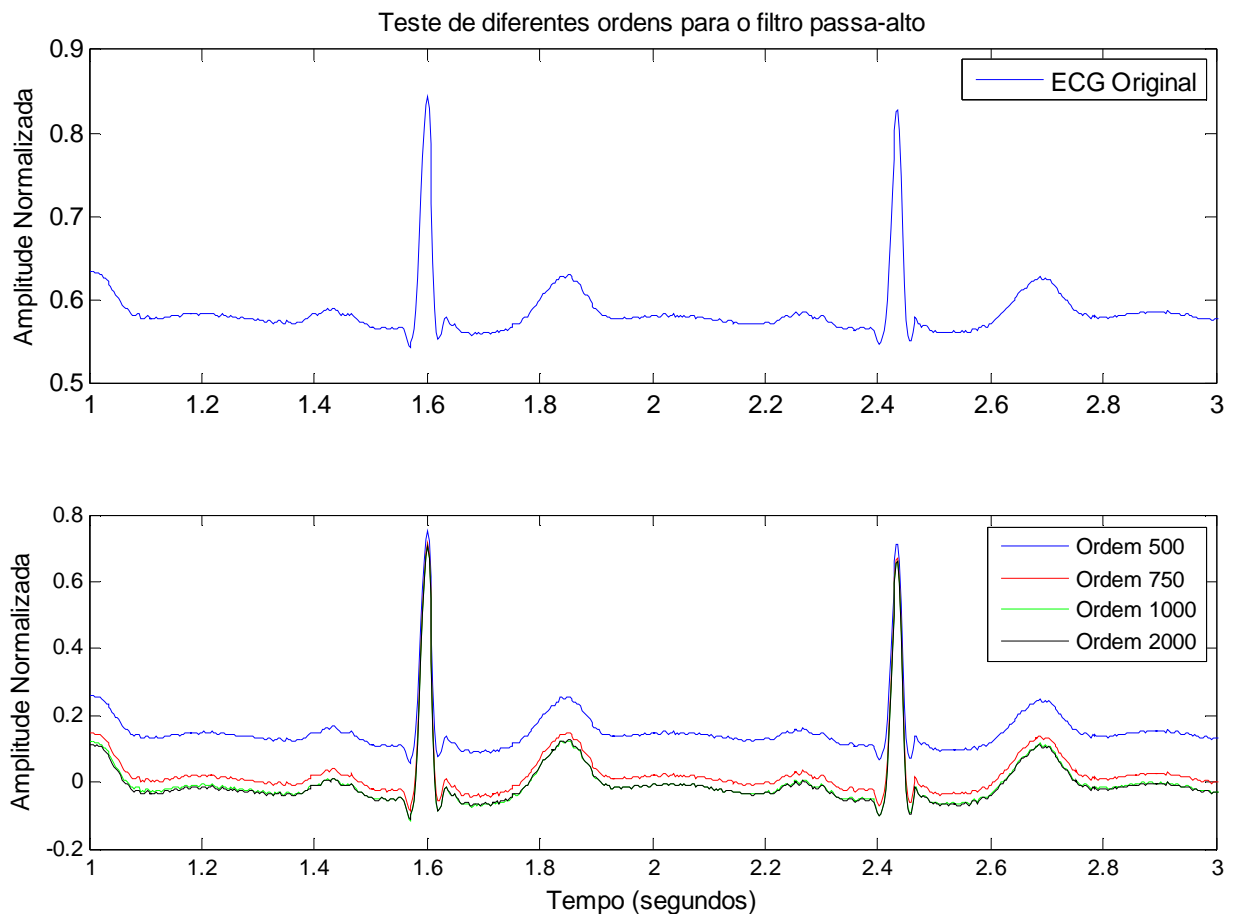


Figura 21 - Teste de diferentes ordens para o filtro passa-alto. A ordem 1000 foi a mínima ordem que permitiu um alinhamento adequado do sinal no nível isoeletrico. Como o método de filtragem usado é a filtragem de fase 0, os filtros aplicados correspondem na realidade a uma ordem que é o dobro da ordem especificada na legenda. O sinal utilizado foi o sinal mit103 da *MIT-BIH Arrhythmia Database*.

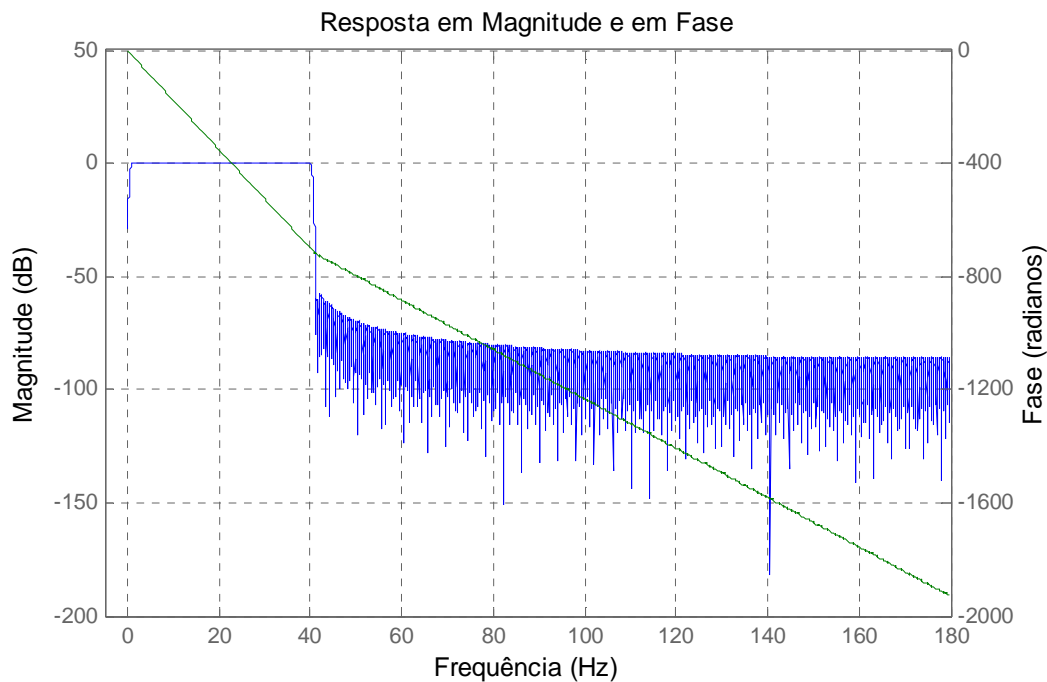


Figura 22 - Resposta em magnitude e em fase da combinação dos dois filtros. Saliente-se que esta representação corresponde às especificações dos dois filtros. Como a filtragem é de fase 0, a resposta em magnitude é o quadrado da resposta representada e a resposta de fase é uma linha reta em 0.

4.2.3 - Detetor de complexos QRS

O detetor de picos elaborado neste projeto foi baseado no algoritmo de Pan-Tompkins [17], [18], mencionado pela primeira vez na secção 3.3. O diagrama de blocos do processamento efetuado aos sinais pelo algoritmo detetor de picos QRS está representado na Figura 23. Os passos do detetor específicos para este trabalho são descritos a seguir:



Figura 23 - Diagrama de blocos do processamento de sinal intrínseco ao detetor de picos QRS.

Os passos do detetor estão explicados em pormenor a seguir:

1. **Filtro passa-banda 5-15 Hz.** A aplicação deste filtro consistiu na aplicação sequencial de um filtro passa-baixo e posteriormente um filtro passa-alto. A tipologia destes filtros é FIR e são baseados no método da janela. A janela utilizada para estes filtros foi uma janela de *Kaiser*. Comparando a janela de *Kaiser* com a janela de *Hamming* utilizada nos filtros de pré-processamento, a janela de *Kaiser* possibilita uma banda de transição mais estreita para uma mesma ordem do filtro. Porém, a banda de corte não tem uma atenuação tão grande como se observa na janela de *Hamming*. Utilizando a janela de *Kaiser* pode ainda estabelecer-se com rigor o compromisso desejado entre a largura da banda de transição e a atenuação na banda de corte, através de um parâmetro β . Quanto maior este parâmetro, maior a atenuação na banda de corte e maior a largura da banda de transição. Por outras

palavras, quanto maior o valor de β , maior é a aproximação da resposta em frequência do filtro com a resposta verificada para a janela de *Hamming*. Quanto menor o valor de β , mais estreita é a banda de transição e menor é a atenuação da banda de corte, com a resposta em frequência a aproximar-se da verificada para a janela retangular. Se $\beta=0$, a janela de *Kaiser* é igual à janela retangular. O valor escolhido para o parâmetro β foi 0.5, visto que neste caso é mais importante definir bem as bandas passante e de corte. A atenuação assume aqui um papel secundário, pois as componentes de interesse serão ainda mais enfatizadas em passos posteriores do detetor de picos. A ordem de ambos os filtros é 50.

Observando o espectro de frequências do sinal ECG (Figura 8), verifica-se facilmente que a banda que centra melhor as frequências mais marcantes do complexo QRS é a banda de 5 a 15 Hz, o que constitui uma das razões da escolha efetuada para a banda passante da filtragem. Inicialmente considerou-se uma banda de 10 a 20 Hz, a fim de prevenir a inclusão de ondas P ou T mais proeminentes no sinal de saída do detetor. Porém, verificou-se experimentalmente que a aplicação dessa banda passante resultava num sinal de saída final (após todos os estágios do detetor) com picos muito heterogêneos no que diz respeito à amplitude. Contrariamente, a banda 5-15 Hz conduziu a um sinal de saída em que as amplitudes dos picos apresentavam valores bastante mais homogêneos, pelo que se enveredou por esta banda passante. Aparentemente, a disparidade de amplitudes verificada mediante a utilização da banda 10-20 Hz não introduziria problemas na deteção dos mesmos. Porém, é evidente que com picos de amplitude semelhante é muito mais fácil definir limiares de deteção. Além do que já foi referido, a banda passante 5-15 Hz encontra-se sugerida na literatura para o detetor de Pan-Tompkins [17], [18].

Os dois filtros foram aplicados de forma convencional, contrariamente ao procedimento de filtragem efetuado no pré-processamento. Isto significa que o sinal resultante vai ter um atraso em relação ao sinal inicial, o qual terá que ser removido. Como estes filtros são de tipologia FIR, o atraso de grupo é o mesmo para todas as frequências da banda passante e igual (em amostras) a metade da ordem do filtro aplicado. Como cada um dos filtros tem ordem 50, o atraso resultante da filtragem é de 50 amostras. Removeram-se então as primeiras 50 amostras do sinal resultante. A resposta em magnitude e em fase da combinação dos dois filtros pode ser visualizada na Figura 24 e o resultado da aplicação dos mesmos a um sinal ECG está representado na Figura 25.

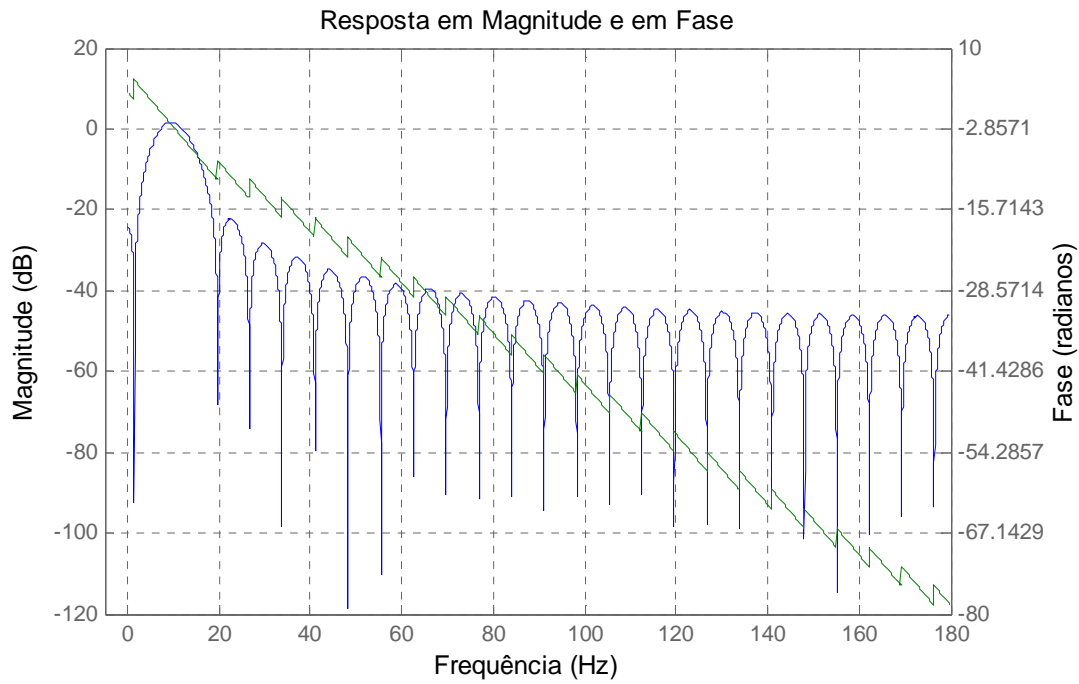


Figura 24 - Resposta em magnitude e em fase da combinação do filtro-passa alto com $F_c = 5$ Hz e do filtro passa-baixo com $F_c = 15$ Hz.




Figura 25 - Resultado da operação de filtragem sequencial do sinal pré-processado com os filtros passa-baixo de 15 Hz e passa-alto de 5 Hz. O sinal filtrado representado encontra-se já com o atraso compensado. O sinal utilizado foi o sinal mit103 da MIT-BIH Arrhythmia Database.

2. **Derivada.** Este passo é muito simples e consistiu apenas em derivar o sinal resultante da filtragem do passo 1. Para este fim, foi utilizado um filtro diferenciador de 1ª ordem simples, cuja equação às diferenças é:

$$y[n] = x[n] - x[n - 1] \quad 4.1$$

O resultado deste passo está representado na Figura 26.

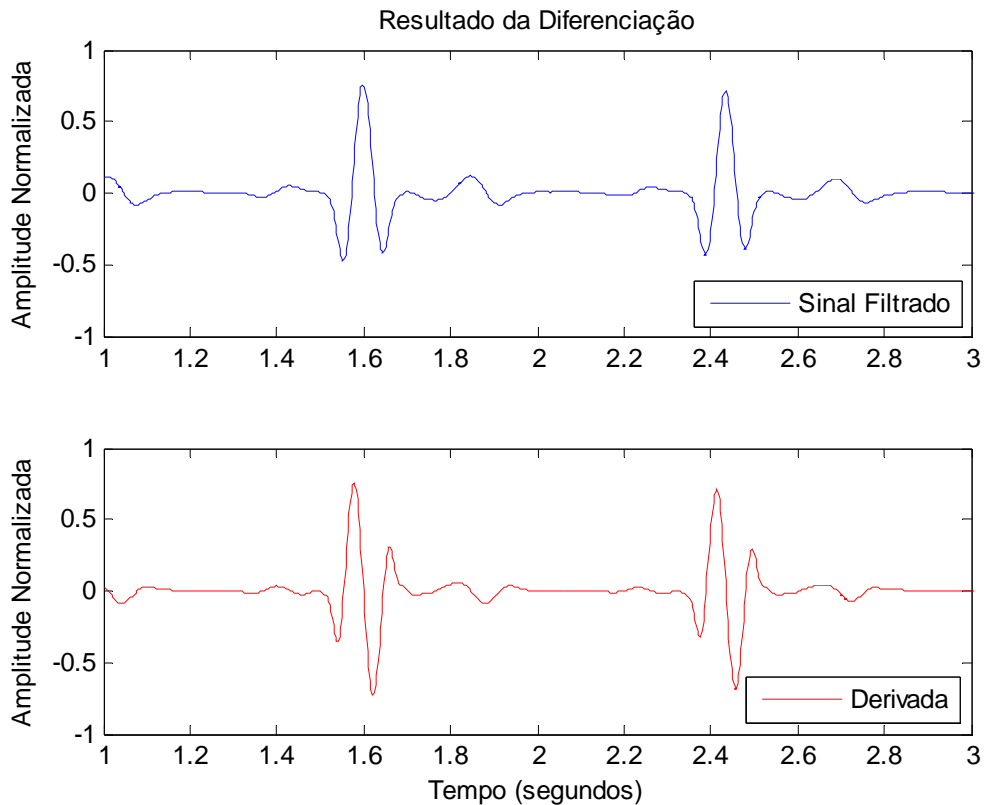


Figura 26 - Diferenciação do sinal filtrado. O sinal utilizado foi o sinal mit103 da MIT-BIH Arrhythmia Database.

3. **Quadrado.** O passo seguinte foi obter o quadrado das amostras do sinal resultante do passo anterior. Para $n =$ comprimento do sinal:

$$y[n] = (x[n])^2 \quad 4.2$$

O resultado desta transformação não linear do sinal está representado na Figura 27.



Figura 27 - Resultado da execução do quadrado da derivada do sinal. O sinal utilizado foi o sinal mit103 da MIT-BIH Arrhythmia Database.

4. **Média móvel.** O último passo do processamento antes da aplicação do critério de decisão do detetor consiste numa suavização do sinal resultante dos passos anteriores. Para este fim, aplicou-se então ao sinal um filtro de média deslizante. É usual incluir na média um número de pontos N correspondente ao número de amostras que representam a largura temporal de um complexo QRS. Um complexo QRS dura sensivelmente 0.2 segundos [1]. Com uma frequência de amostragem de 360 Hz, o valor de N será $0.2 \times 360 \approx 72$.

Desta forma, considerou-se $N = 72$ como o parâmetro do filtro. Uma vez que o filtro tem 72 coeficientes, a ordem do mesmo é 71. Este filtro também é FIR e portanto provoca no sinal resultante um atraso constante que assume o valor de metade da sua ordem. Neste caso o valor teórico para este atraso é não inteiro (35.5), e a compensação foi feita através da remoção das 36 primeiras amostras do sinal.

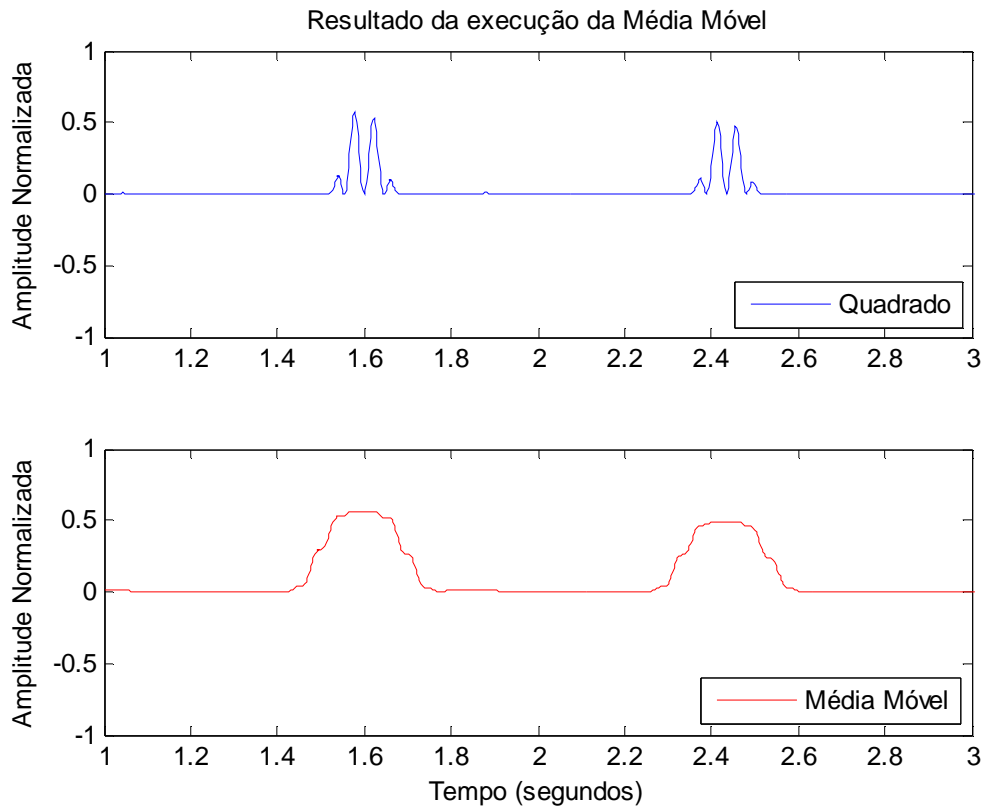


Figura 28 - Resultado da execução de uma média móvel de 72 pontos ao sinal resultante do passo anterior. O sinal resultante representado encontra-se já com o atraso compensado. O sinal utilizado foi o sinal mit103 da *MIT-BIH Arrhythmia Database*.

Ao longo destes passos de filtragem, a correção dos atrasos teve um papel essencial, uma vez que o sinal de saída de todo o processamento vai agora ser sobreposto ao sinal ECG pré-processado para se efetuar a deteção de picos. A sobreposição dos dois sinais pode ser visualizada na Figura 29.

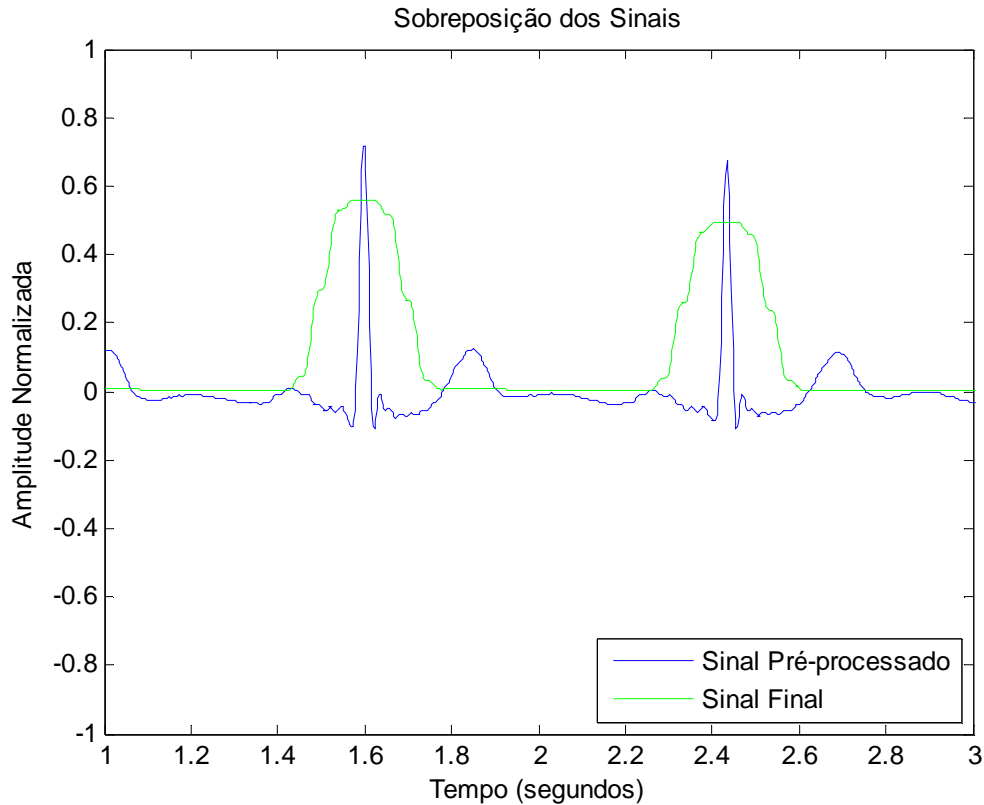


Figura 29 - Sobreposição do sinal pré-processado com o sinal resultante do processamento intrínseco ao detetor de picos. O sinal utilizado foi o sinal mit103 da *MIT-BIH Arrhythmia Database*.

Como se pode verificar na Figura 29, o sinal final do processamento do detetor (a verde) apresenta proeminências de amplitude que estão alinhadas com a ocorrência de complexos QRS no sinal ECG pré-processado. Em todos os outros momentos do sinal ECG, incluindo a ocorrência de ondas P, T e de eventuais artefactos, o sinal final mantém um valor de aproximadamente 0. Desta forma, o sinal final funciona como um indicador de limites de procura do pico R para cada ciclo cardíaco. A partir das localizações encontradas para os picos R, determinam-se também as localizações dos picos Q e S. Segue-se uma explicação ilustrada nos diagramas de blocos das Figura 30 e Figura 31.

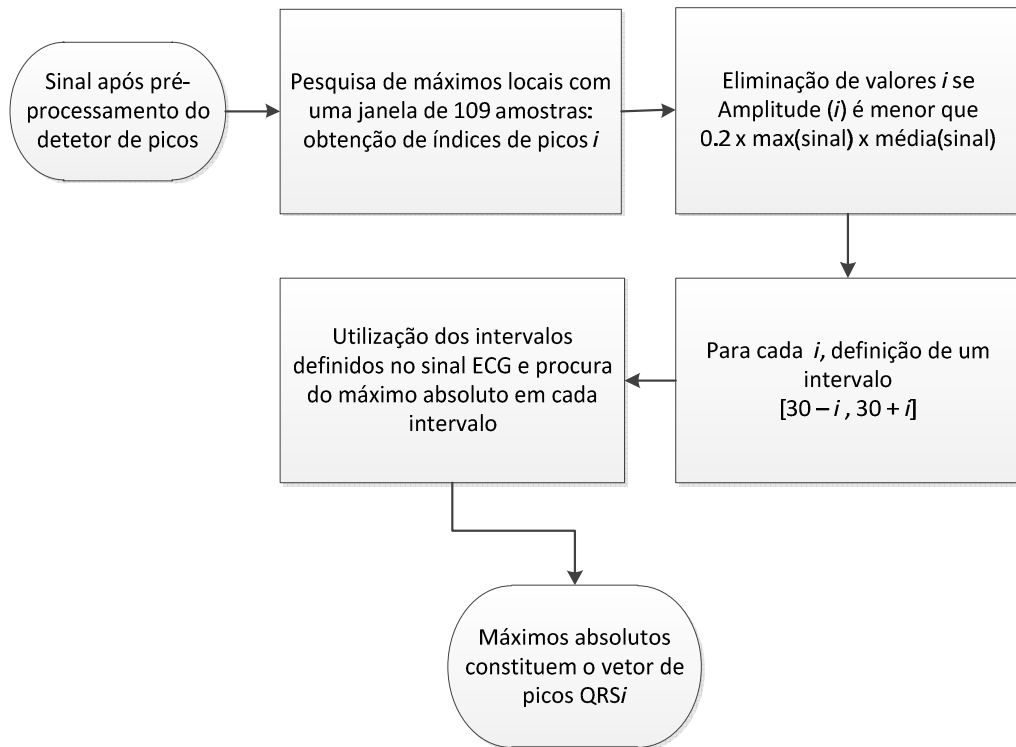


Figura 30 - Diagrama de blocos referente à lógica de detecção de picos R.

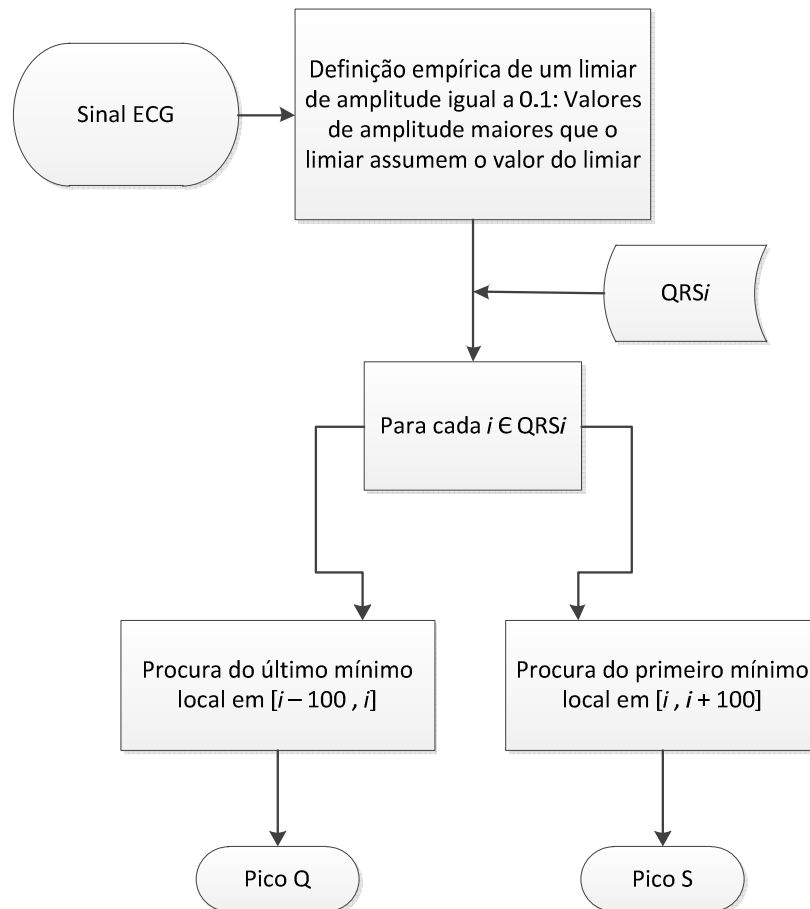


Figura 31 - Diagrama de blocos referente à lógica de detecção de picos Q e S.

Os passos inerentes à deteção de picos Q, R e S são explicados em pormenor a seguir:

1. Para o sinal processado (a verde na Figura 29), procuram-se os máximos locais de acordo com uma janela de 109 amostras. Isto é, para cada ponto do sinal, é verificada a amplitude das 54 amostras à sua direita e das 54 amostras à sua esquerda. Se não houver nenhuma amostra com amplitude maior do que a do ponto central, então o ponto é máximo. Em situações de pontos iniciais do sinal para os quais ainda não há 54 amostras à esquerda, a verificação do lado esquerdo é efetuada a partir da primeira amostra do sinal e, homologamente, em pontos finais do sinal para os quais já não há 54 amostras à direita, a verificação do lado direito é feita até à última amostra do sinal. A janela de 109 amostras foi escolhida para exceder um pouco a duração de um complexo QRS (72 amostras como visto acima), mas ficando ainda longe da duração de um ciclo cardíaco dos mais curtos. Com uma janela de procura de duração ligeiramente maior do que a duração de um complexo QRS, previne-se a deteção de oscilações transitórias do sinal que nada têm a ver com os complexos QRS, mas sim com artefactos mais marcantes que podem ter uma frequência muito próxima da dos complexos QRS.
2. Uma vez obtido o conjunto de máximos, estabeleceu-se um limiar para que fossem eliminados todos os máximos locais detetados cuja amplitude fosse inferior ao mesmo. Esse limiar é $0.2 \times \text{maximo do sinal} \times \text{média do sinal}$. Obtém-se assim um conjunto mais restrito de valores.
3. Para cada máximo, define-se um segmento de procura com um tamanho de 61 amostras centrado no índice do máximo (30 amostras para a esquerda e 30 amostras para a direita).
4. Cada um dos segmentos definidos no passo anterior é transposto para o sinal ECG original (pré-processado) e em cada um deles é procurado o índice para o qual o valor de amplitude do sinal ECG é máximo. Os índices encontrados correspondem aos picos R.
5. A partir da localização dos picos R, determina-se a localização dos picos Q e S. Para isto, primeiro define-se um limiar de 0.1 em todo o sinal. Depois, partindo da localização de cada um dos picos R, definem-se dois segmentos de procura. Um deles é definido desde o ponto localizado 100 amostras para trás do pico R até ao próprio pico R. O outro segmento é definido desde o pico R até ao ponto localizado 100 amostras para a frente do mesmo. Para o primeiro segmento, é procurado o último mínimo local que tenha uma amplitude inferior ao limiar definido, encontrando-se assim o pico Q. Para o segundo segmento, é procurado o primeiro mínimo local com amplitude inferior ao limiar, encontrando-se assim o pico S.

O resultado final do detetor está ilustrado na Figura 32, onde estão indicadas as localizações dos picos Q, R e S para dois ciclos cardíacos.

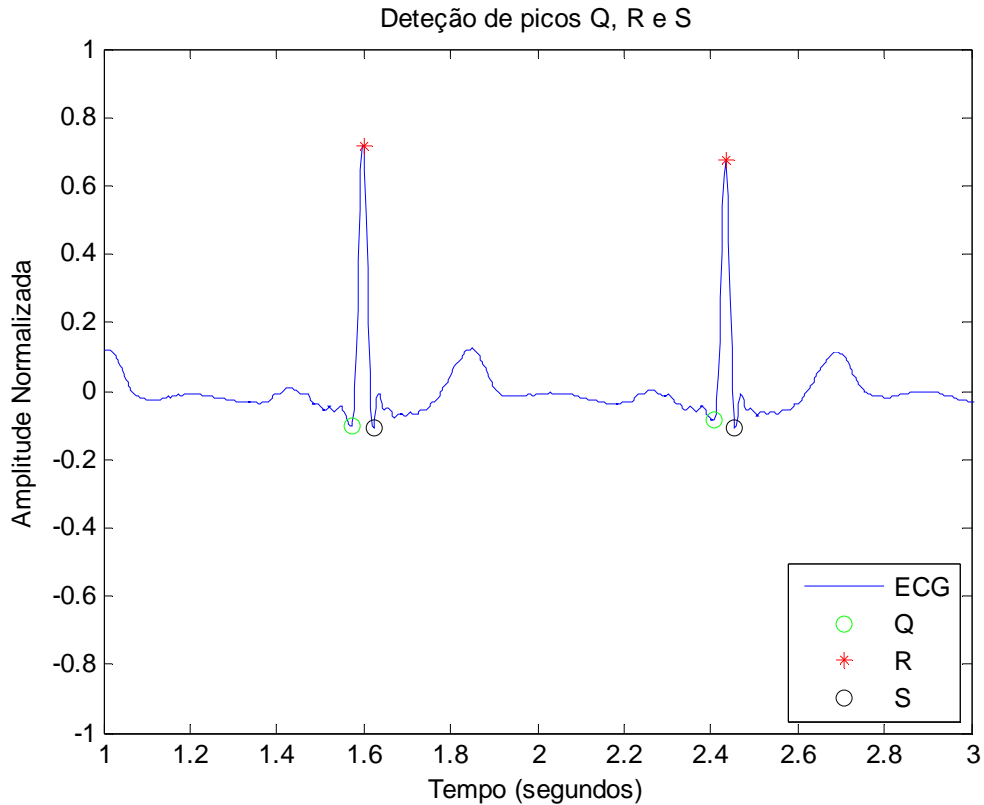


Figura 32 - Resultado de detecção, com a indicação da localização dos picos Q, R e S. O sinal utilizado foi o sinal mit103 da *MIT-BIH Arrhythmia Database*.

A detecção dos picos Q, R e S constitui a base fundamental para o desenvolvimento do trabalho que se segue. Para a construção de um primeiro algoritmo, muito simples, de detecção de ESV, basta conhecer as localizações dos picos R, enquanto que para a extração de características dos batimentos cardíacos é necessário também conhecer as localizações dos picos Q e S.

4.2.4 - Primeiro algoritmo detetor de ESV

Após a detecção dos picos, e sabendo que cada pico R detetado está associado a um ciclo cardíaco, é possível determinar o número de batimentos cardíacos presentes num sinal, e consequentemente a frequência cardíaca do indivíduo. A frequência cardíaca instantânea mede, para cada pico QRS, o intervalo de tempo que vai desde a ocorrência do pico atual até à ocorrência do pico seguinte. Sendo $n = [1, comprimento\ do\ sinal - 1]$, F_s a frequência de amostragem do sinal e QRS_i o vetor de índices de cada pico QRS,

$$BPM(n) = \frac{F_s \times 60}{QRS_i(n+1) - QRS_i(n)} \quad 4.3$$

Uma vez que em geral as ESV apresentam uma prematuridade evidente, observando-se uma pausa compensatória maior do que é normal para o batimento seguinte, esta medida revela-se bastante útil na detecção da ocorrência de ESV. Para um dado batimento cardíaco n_i

associado a uma ESV, $BPM(n_i - 1)$ terá um valor consideravelmente maior do que os valores normais de BPM , enquanto que $BPM(n_i)$ terá um valor consideravelmente menor (Figura 33).

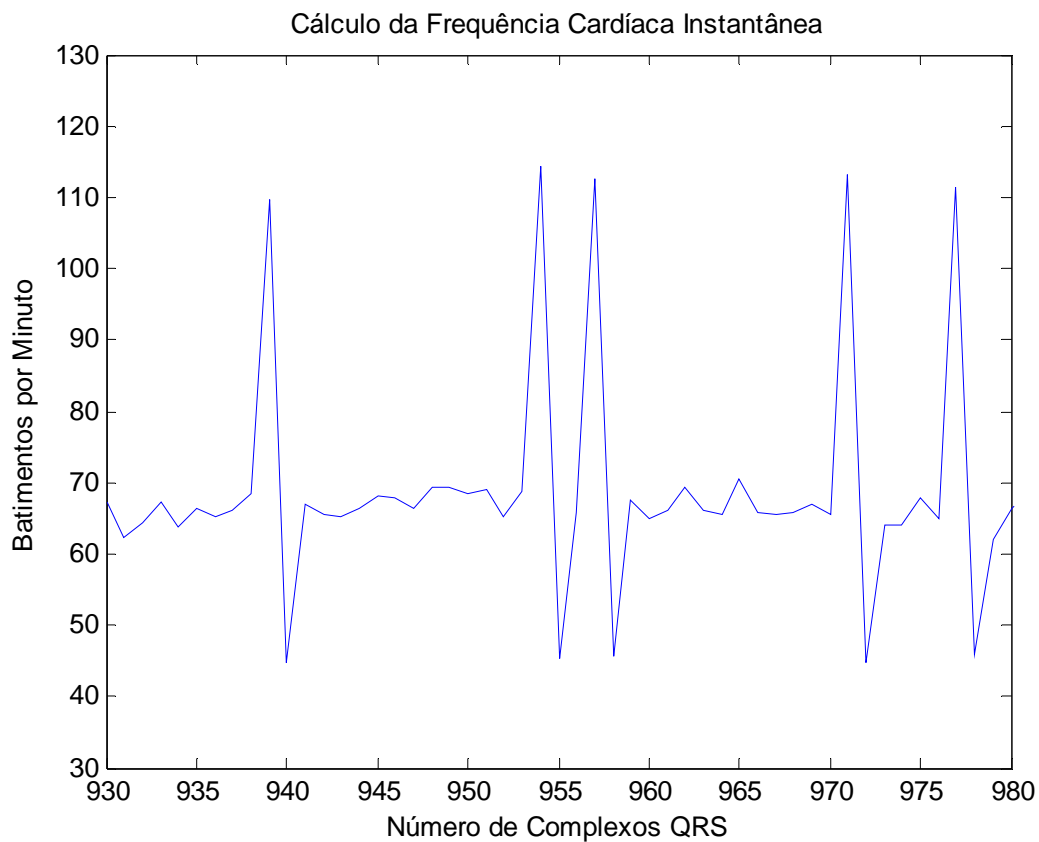


Figura 33 - Pequeno segmento do vetor BPM relativo ao sinal mit119 da *MIT-BIH Arrhythmia Database*. Evidenciam-se 5 ocorrências de ESV, onde se verifica um pico de amplitude anormalmente baixo precedido de um pico anormalmente elevado.

Para enfatizar as diferenças verificadas no vetor BPM para o caso das ESV, foi utilizado um filtro diferenciador simples de 1ª ordem. Antes da aplicação do filtro ao vetor BPM , fez-se uma subtração da média do vetor ao próprio vetor, de forma a alinhar os valores médios em zero. Após este passo aplicou-se então o filtro, cuja equação às diferenças é:

$$y[n] = x[n] - x[n - 1] \quad 4.4$$

O resultado da aplicação deste filtro ao segmento da Figura 33 pode ser visualizado na Figura 34. Como se pode verificar, a aplicação do filtro conduz a um realce das características de BPM , sobretudo no que diz respeito aos picos negativos.

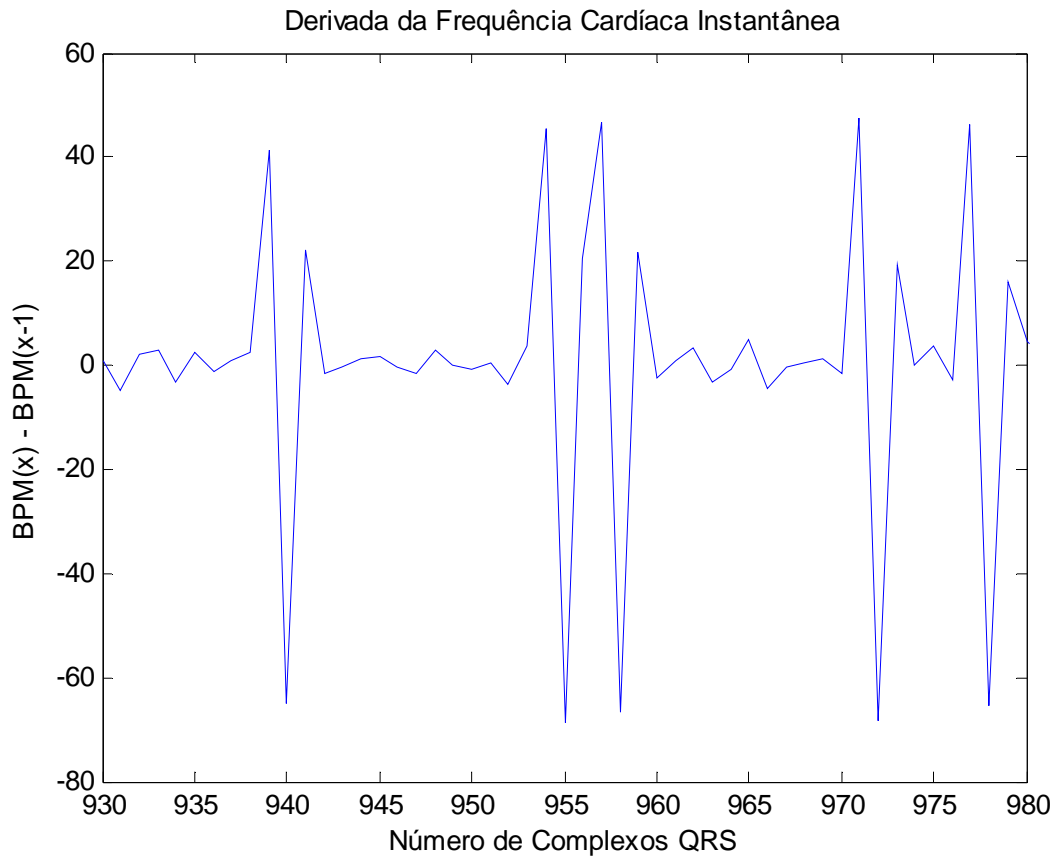


Figura 34 - Derivada da frequência cardíaca instantânea (dBPM).

Uma vez obtidos os sinais correspondentes à derivada da frequência cardíaca instantânea para cada sinal (dBPM), foram definidos 2 limiares, um inferior e outro superior. Para o limiar inferior, foi efetuada uma média de todos os valores de amplitude de dBPM menores que -10 e foi considerada a percentagem de 40% desse valor. Para o limiar superior foi considerado o valor absoluto do limiar inferior. Uma vez definidos estes limiares, aplicou-se uma lógica de detecção de ESV. O princípio básico é a associação de valores menores que o limiar negativo a ESV. Porém, alguns padrões de ocorrência de ESV podem levar a alterações no vetor dBPM, o que pode implicar que nem só os valores abaixo do limiar negativo correspondam a ESV. O diagrama de blocos geral do algoritmo está representado na Figura 35 e a respetiva lógica de detecção está representada na Figura 36.

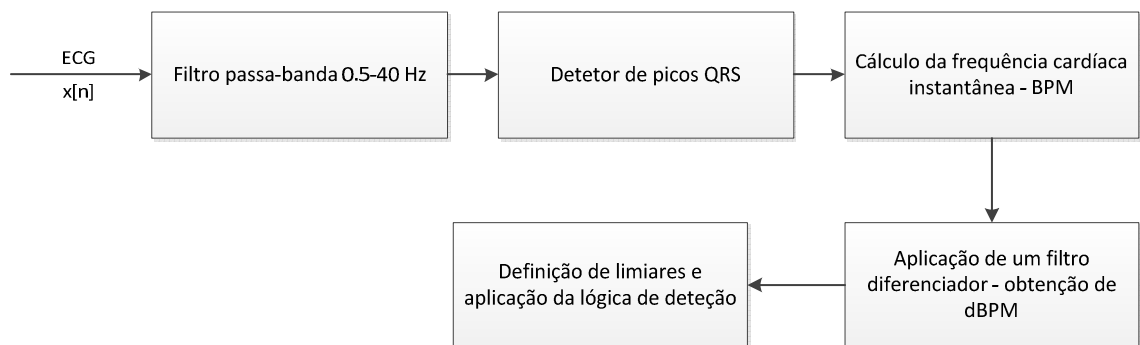


Figura 35 - Diagrama de blocos geral do algoritmo detector de ESV.

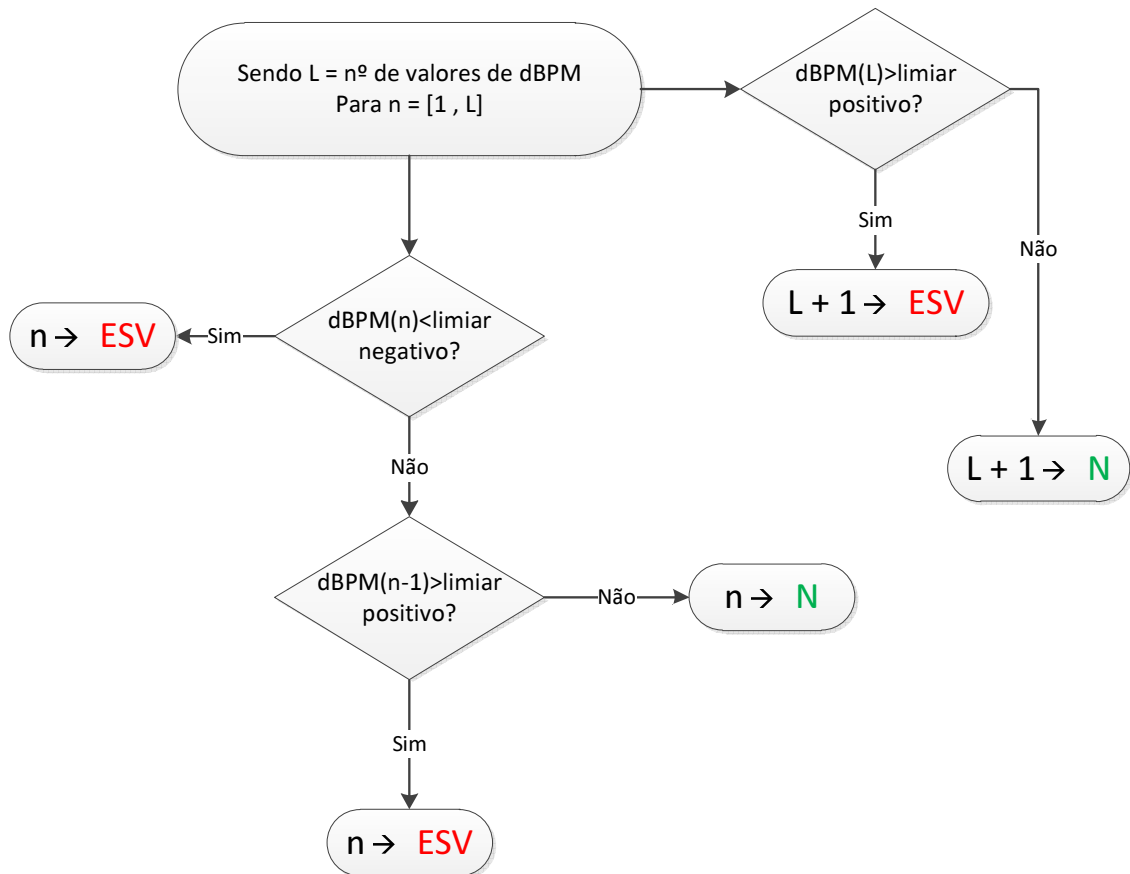


Figura 36 - Diagrama de blocos ilustrativo da lógica de detecção de ESV no algoritmo proposto. Os índices n correspondem a posições de ESV no vetor de picos R.

A lógica de detecção de ESV, representada na Figura 36, prevê situações em que ocorrem duas ESV consecutivas.

4.2.5 - Extração e processamento de características

A partir da detecção de picos QRS efetuada, extraíram-se várias características dos complexos QRS dos diferentes sinais, para posteriormente se aplicarem algoritmos de classificação aos dados. As características extraídas foram as seguintes:

- Amplitude do pico R (Amp_R);
- Amplitude do pico Q (Amp_Q);
- Amplitude do pico S (Amp_S);
- Amplitude mínima do segmento de sinal definido entre o pico R atual e o pico R seguinte (Max_neg);
- Duração do segmento Q-R, em segundos (Dur_QR);

- Duração do segmento R-S, em segundos (Dur_RS);
- Duração do segmento Q-S, em segundos (Dur_QS);
- Diferença de amplitude entre o pico R e o pico Q (Dif_RQ);
- Diferença de amplitude entre o pico R e o pico S (Dif_RS);
- Frequência cardíaca instantânea calculada a partir do intervalo de tempo entre a ocorrência do pico R atual e o pico R seguinte (BPM). Este foi o parâmetro utilizado na construção do primeiro algoritmo detetor de ESV (ver equação 4.3). Para o último batimento cardíaco de cada sinal este cálculo não pode ser efetuado. Por isso, para atribuir um valor de frequência cardíaca instantânea para as últimas instâncias dos sinais e dado que em todos os sinais essa instância corresponde a um batimento normal, para cada sinal calculou-se a média dos valores de frequência cardíaca instantânea das instâncias correspondentes a batimentos cardíacos normais e atribuiu-se esse valor à última instância do sinal.

- Razão entre a amplitude do pico R e a amplitude do pico Q, de acordo com a fórmula:

$$Razao_{RQ} = \frac{Amplitude\ R}{Amplitude\ Q} \quad 4.5$$

- Razão entre a amplitude do pico R e a amplitude do pico S, de acordo com a fórmula:

$$Razao_{RS} = \frac{Amplitude\ R}{Amplitude\ S} \quad 4.6$$

- Relação de amplitudes (Relacao_Amps), de acordo com a fórmula:

$$Relacao_{Amps} = \frac{Amplitude\ R - Amplitude\ S}{Amplitude\ R - Amplitude\ Q} \quad 4.7$$

- Relação de durações (Relacao_Durs), de acordo com a fórmula:

$$Relacao_{Durs} = \frac{t_R - t_S}{t_R - t_Q} \quad 4.8$$

- Área de valores absolutos do complexo QRS, calculada através da regra trapezoidal (Ar_abs);
- Área de valores positivos do complexo QRS, calculada através da regra trapezoidal (Ar_pos);
- Área de valores negativos do complexo QRS, calculada através da regra trapezoidal (Ar_neg);

- Declive de subida do complexo QRS, calculado com base numa reta que se ajusta a 11 amostras, sendo elas o pico R mais os 10 pontos que o antecedem (D_esq);
- Declive de descida do complexo QRS, calculado com base numa reta que se ajusta a 11 amostras, sendo elas o pico R mais os 10 pontos que se lhe seguem (D_dir);
- Número de amostras que apresentam um valor de amplitude maior do que 70% do valor de amplitude do pico R (N_val).

Na Figura 37 estão representadas cinco características extraídas através de medições de amplitudes e durações.




Figura 37 - Exemplo de algumas características extraídas através de medição de amplitudes e durações. O ciclo cardíaco apresentado é uma ESV do sinal mit119 da MIT-BIH Arrhythmia Database.

Os batimentos cardíacos que não foram detetados pelo detetor de complexos QRS construído foram excluídos da extração de características, evitando-se assim a realização da anotação manual desses picos. A exclusão dessas instâncias não tem uma importância crítica, uma vez que se registaram muito poucas falhas como se poderá verificar mais à frente na secção 4.3.1. Além dos batimentos cardíacos não detetados, excluíram-se as ocorrências de um tipo de batimento arritmico nos sinais - os batimentos de fusão. Estes batimentos foram excluídos, uma vez que a *Association for the Advancement of Medical Instrumentation* (AAMI) não recomenda a sua rotulagem como batimentos normais nem como ESV (VII).

No total, foram extraídas características de 13892 batimentos cardíacos, divididos em 11763 batimentos normais e 2129 ESV.

Todos os passos da metodologia descritos até agora, desde o projeto dos filtros de pré-processamento até à etapa de extração de características acima descrita, foram realizados com recurso ao *software MATLAB R2011b*.

Após a extração de características, aplicaram-se métodos de redução da dimensão das mesmas. A primeira avaliação das características extraídas foi feita através de um teste estatístico não paramétrico: teste de *Kruskal Wallis*. Este teste fornece um *ranking* de características baseado na sua capacidade discriminativa nas duas classes [28]. O teste de *Kruskal Wallis* foi realizado com recurso ao *software SPSS Statistics 17*. Com recurso a este *software* foram também construídos 40 diagramas de caixa - para cada característica construíram-se dois diagramas, cada um correspondendo às instâncias de uma classe. Desta forma verifica-se o modo como a distribuição dos dados varia de acordo com a classe, em termos de mediana, quartis, extremos e *outliers*.

Os testes seguintes deste trabalho foram executados com recurso ao *software de data mining WEKA 3.6*.

Após a realização do teste de *Kruskal Wallis*, foi aplicado um algoritmo de pesquisa do melhor subconjunto de características partindo do conjunto original - *Exhaustive Search*. O algoritmo de pesquisa *Exhaustive Search* analisa todas as combinações possíveis de características de forma exaustiva e faz a seleção do melhor subconjunto, de acordo com determinado critério [29].

Foram aplicados dois critérios na pesquisa:

- *Cfs Subset Eval*. Avalia o mérito de um subconjunto de atributos considerando o valor preditivo individual de cada um, juntamente com o grau de redundância entre eles [29].
- *Consistency Subset Eval*. Avalia o mérito de um subconjunto de atributos pelo nível de consistência dos valores verificados para cada classe quando as instâncias de treino são projetadas no subconjunto de atributos [29].

4.2.6 - Teste de parâmetros para os algoritmos de classificação

De seguida apresenta-se uma descrição dos dois algoritmos de classificação utilizados neste projeto: *Support Vector Machines* e *Kth Nearest Neighbors rule*.

Support Vector Machines

A ideia central do algoritmo SVM é o ajustamento de uma função discriminante que otimize a separação de padrões fronteiriços [19]. No caso mais simples os padrões são linearmente separáveis, isto é, existe uma função da forma

$$f(x) = w^T x + b \quad 4.9$$

em que x é um vetor de características e w é o vetor de pesos associados a cada característica, tal que, para cada amostra de treino x_i , a função pode dar origem a $f(x_i) \geq 0$ para $y_i = +1$ e $f(x_i) < 0$ para $y_i = -1$. Estes dois casos correspondem a classes de dados distintas e são separados pelo hiperplano $f(x) = w^T x + b = 0$. Para determinado *training set*, de entre a variedade de hiperplanos que possam separar as duas classes, o classificador SVM utiliza aquele que maximiza a margem que separa as duas classes [26], [29], [30]. Matematicamente, o hiperplano é encontrado através da minimização da função de custo

$$J(w) = \frac{1}{2} w^T w = \frac{1}{2} \|w\|^2 \quad 4.10$$

Sujeita à restrição $y_i(w^T x_i + b) \geq 1$ para $i = 1, 2, \dots, l$. Se os dados de treino não forem completamente separáveis por um hiperplano, são introduzidas variáveis para flexibilizar as restrições de separação, da seguinte forma

$$y_i(w^T x_i + b) \geq 1 - \xi_i, \xi_i \geq 0; i = 1, 2, \dots, l. \quad 4.11$$

Modificando a função de custo da seguinte forma:

$$J(w) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad 4.12$$

em que C é um parâmetro positivo de regularização especificado pelo utilizador. A função de custo modificada constitui o risco estrutural, que faz o balanceamento do risco empírico (erros de treino refletidos no segundo termo) com a complexidade do modelo (o primeiro termo). O parâmetro C controla este compromisso. O propósito de utilizar a complexidade do modelo para restringir a otimização do risco empírico é a prevenção do *overfitting*. O *overfitting* é uma situação em que a fronteira de decisão corresponde de forma muito precisa ao *training set*, e que por isso não tem um bom desempenho na classificação de novos dados [26].

O SVM linear pode ser estendido a não linear utilizando um operador não linear para mapear os padrões de entrada x num espaço com mais dimensões. Este classificador define-se como

$$f(x) = w^T \phi(x) + b \quad 4.13$$

A seguir à transformação não linear, os parâmetros da função de decisão $f(x)$ são determinados pela seguinte minimização:

$$\min J(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \quad 4.14$$

sujeita a $y_i(w^T \phi(x_i) + b) \geq 1 - \xi_i, \xi_i \geq 0; i = 1, 2, \dots, l$. O mapeamento $\phi(\cdot)$ pressupõe a definição de um *Kernel* $K(\cdot, \cdot)$ que defina $\phi(\cdot)$. Os *Kernels* podem ser polinomiais, gaussianos ou funções de base radial (*Radial Basis Functions*) [26], [29], [30].

Kth Nearest Neighbors Rule

Este algoritmo de classificação baseia-se num método simples, e faz a classificação diretamente a partir das posições dos vetores de características que integram o *training set* [23]. Ao contrário do classificador SVM, cujo treino consiste em definir um hiperplano que separa os padrões por classes, o treino do algoritmo KNN consiste apenas no armazenamento dos vetores de características de treino, juntamente com a identificação da respetiva classe. Considere-se um vetor de entrada x que vai ser classificado. A classe que lhe é atribuída é a classe que predomina nos seus K vizinhos mais próximos integrantes do *training set*. A proximidade entre as instâncias é calculada através de uma determinada métrica de distância, geralmente a distância euclidiana, definida como

$$d = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad 4.15$$

Onde x e y são vetores de características, n é a dimensão dos mesmos e i é o índice de cada característica. É boa prática utilizar um número ímpar para K , de modo a evitar empates na classe dos vizinhos mais próximos [19], [23].

Numa fase inicial de classificação, foram testados alguns parâmetros para os algoritmos de classificação. Testaram-se diferentes valores para K no caso do algoritmo KNN, e testaram-se algumas combinações de diferentes graus de *kernels* polinomiais com diferentes parâmetros C para SVM. Embora nos diferentes estudos reportados na literatura se utilizem *Radial Basis Functions* como *kernel* [24-26], neste projeto convencionou-se a utilização de *kernels* polinomiais devido ao facto de estes, mediante o grau utilizado, permitirem a definição de regiões de separação bastante flexíveis. Para estes testes iniciais utilizou-se o conjunto total inicial de 20 características.

A classificação foi feita recorrendo a dois métodos. No primeiro método, denominado *k-fold cross-validation*, inicialmente escolhe-se um valor para k , que representa as *folds* ou partições de dados. Seguidamente, o conjunto global de dados é dividido k partições aproximadamente iguais, cada uma das quais contém instâncias aleatórias dos dados a analisar. Depois, num processo de classificações sequenciais cada uma das k partições é utilizada para teste e as restantes $k - 1$ partições utilizadas para treino. O processo é repetido k vezes, para que cada uma das k partições seja utilizada para teste uma vez. Finalmente é feita uma média dos erros de classificação das k classificações, dando origem a uma estimativa de erro global. Neste trabalho utilizou-se $k = 10$, uma vez que está

demonstrado que este número é aproximadamente o ideal para obter a melhor estimativa de erro do classificador, e atualmente é o valor padrão utilizado em termos práticos [29].

O segundo método baseia-se no método *leave-one-out* [29], e consiste numa espécie de *cross-validation*, mas aqui considera-se um número de partições igual ao número de sinais ECG diferentes a analisar, que neste caso são cinco. Além disso, as partições não são aleatórias, cada uma delas correspondendo a um sinal individual. Posteriormente são efetuadas cinco classificações, sendo que em cada uma um sinal individual é utilizado para teste e os restantes para treino. Desta forma, as instâncias do sinal a classificar não são incluídas no conjunto de treino, o que conduz a erros de classificação mais realistas.

4.2.7 - Teste de características e classificação

Depois de terem sido selecionados parâmetros para os dois classificadores, os dados foram classificados utilizando diferentes subconjuntos de características e recorrendo ao método *10-fold cross validation* descrito na secção 4.2.6.

O subconjunto de características que conduziu a melhores resultados foi submetido a um novo método de redução de dimensão de características - *Principal Component Analysis - PCA*. O método PCA fornece uma matriz que permite transformar o conjunto de atributos num outro conjunto mais reduzido, em que os novos atributos consistem em combinações lineares dos atributos prévios e são idealmente mais discriminativos [25], [29]. O conjunto de *Principal Components* obtido foi também testado com os dois classificadores.

Por fim, o melhor subconjunto de atributos de todas as análises efetuadas foi utilizado na classificação através do método *leave-one-out*, a fim de se obterem resultados mais realistas e que possam ser comparados com os resultados obtidos para o primeiro algoritmo simples de deteção de ESV.

4.3 - Resultados e discussão

Nesta secção são apresentados os resultados para o desempenho dos algoritmos aplicados aos sinais escolhidos para este trabalho. As medidas de eficácia utilizadas são a taxa de sucesso da classificação, sensibilidade (SE), especificidade (SP), valor de predição positiva ou precisão (P+) e F1, que consistem em relações entre o número de verdadeiros positivos (VP), verdadeiros negativos (VN), falsos positivos (FP) e falsos negativos (FN). De seguida apresenta-se uma definição destes conceitos, bem como as fórmulas de cálculo de cada uma das medidas de eficácia.

No contexto da classificação associada a este trabalho, um VP representa uma deteção correta de uma ESV. Um VN consiste, por sua vez, consiste num batimento cardíaco normal corretamente identificado. Um FP representa um batimento normal incorretamente detetado como ESV e um FN representa uma classificação incorreta de um batimento como normal quando de facto corresponde a uma ESV [10]. As medidas de eficácia calculam-se da seguinte forma:

$$Taxa\ de\ sucesso(\%) = \frac{VP + VN}{VP + FP + VN + FN} \times 100 \quad 4.16$$

$$SE(\%) = \frac{VP}{VP + FN} \times 100 \quad 4.17$$

$$SP(\%) = \frac{VN}{VN + FP} \times 100 \quad 4.18$$

$$P+(\%) = \frac{VP}{VP + FP} \times 100 \quad 4.19$$

$$F1 = \frac{2 \times SE \times (P+)}{SE + (P+)} \times \frac{1}{100} \quad 4.20$$

A taxa de sucesso representa a percentagem de instâncias de teste cuja classe foi corretamente identificada relativamente ao número total das instâncias de teste. A SE é uma medida da capacidade do algoritmo para identificar casos positivos (ESV neste caso), enquanto que a SP é uma medida da capacidade de identificação de casos negativos (batimentos normais neste caso). O parâmetro P+ reflete a probabilidade de uma instância que é identificada como positiva ser efetivamente positiva na realidade, constituindo assim uma medida crítica do desempenho de um método de diagnóstico. Por último, o parâmetro F1 é uma média harmónica de SE e P+ [29].

4.3.1 - Detetor de complexos QRS

Na Tabela 5 apresentam-se os resultados do desempenho do algoritmo de deteção de picos R em termos de sensibilidade e precisão, para cada um dos cinco sinais utilizados.

Tabela 5 - Avaliação de desempenho do detetor de picos R. VP -Verdadeiro Positivo; FP-Falso Positivo; FN-Falso Negativo. SE-Sensibilidade; P+-Precisão.

Sinais	Número de ciclos cardíacos	VP	FP	FN	SE (%)	P+(%)
mit119	1987	1987	0	0	100	100
mit213	3251	3249	0	2	99,94	100
mit215	3363	3363	1	1	99,97	99,97
mit223	2605	2604	0	1	99,96	100
mit233	3079	3077	0	2	99.94	100

Como se pode verificar através da tabela, os resultados de deteção de picos R foram bastante satisfatórios, com os parâmetros de eficácia a revelarem-se muito próximos de 100% em todos os casos. No caso do sinal mit215, é apresentado um FP e um FN apenas porque um dos picos R é detetado com uma ligeira deslocalização relativamente ao local real do mesmo.

É importante salientar que é necessário assegurar uma detecção de picos com parâmetros de sensibilidade e precisão muito próximos dos 100%, uma vez que falhas de detecção e/ou falsas detecções constituem uma fonte primária de erro, que se propaga nos passos subsequentes do processamento do sinal ECG.

A eficácia do algoritmo está expressa apenas relativamente à detecção de picos R, uma vez que estes picos são os únicos que se encontram nas anotações da base de dados, servindo como ponto de referência único de cada ciclo cardíaco. Os picos Q e S não estão anotados, e uma anotação manual destes picos também não se revelou viável, por duas razões: no conjunto dos cinco sinais utilizados estão presentes 14285 ciclos cardíacos, correspondendo a um conjunto de picos (Q e S) igual ao dobro desse valor; em algumas zonas de cada sinal, é difícil identificar o padrão exato do complexo QRS. No sentido de analisar a detecção destes picos foi efetuada uma inspeção visual aos sinais, com resultados gerais aparentemente razoáveis. Em alguns casos a detecção revelou-se menos boa, com algumas deslocalizações mais ou menos evidentes. Porém, não é possível quantificar estes erros de forma fidedigna.

4.3.2 - Primeiro algoritmo detetor de ESV

Na Tabela 6 estão representados os resultados do desempenho do primeiro algoritmo construído para detecção de ESV, avaliado com recurso aos cinco sinais selecionados da *MIT-BIH Arrhythmia Database*.

Tabela 6 - Avaliação do desempenho do primeiro detetor de ESV. VP-Verdadeiros Positivos; VN-Verdadeiros Negativos; FP-Falsos Positivos; FN-Falsos Negativos; SE-Sensibilidade; SP-Especificidade, P+-Precisão.

	VP	VN	FP	FN	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F1
mit119	443	1542	0	1	99,95	99,77	100,00	100,00	0,999
mit213	113	2991	40	107	95,48	51,36	98,68	73,86	0,606
mit215	145	3193	6	19	99,26	88,41	99,81	96,03	0,921
mit223	361	2055	77	112	92,74	76,32	96,39	82,42	0,793
mit233	767	2236	12	65	97,50	92,19	99,47	98,46	0,952
Média					96,99	81,61	98,87	90,15	0,854

O melhor resultado de detecção verifica-se para o sinal mit119. Este sinal é o único dos cinco utilizados que apresenta ESV uniformes, o que lhe confere uma morfologia bem definida com um padrão de ESV que se repete ao longo do tempo. Portanto, era esperado que este sinal fosse aquele que permitisse um melhor desempenho ao detetor. Embora a taxa de sucesso da classificação seja superior a 90% em todos os casos, há que constatar os valores menos bons de sensibilidade, com especial destaque para o caso do sinal mit213. Nesse caso, o valor desce aos 51%, que é um valor muito reduzido considerando o contexto da utilização de um algoritmo deste tipo. Esta é uma clara evidência de que a prematuridade de ocorrência, apesar de ser um forte indicador, não é um parâmetro absoluto de discriminação de ESV. No caso dos sinais mit213, mit215 e mit223, apesar dos valores de sensibilidade não

serem marcadamente baixos, é necessário um valor deste parâmetro consideravelmente superior para funcionamento em contexto real.

4.3.3 - Extração e processamento de características

Depois da extração das características mencionadas na secção 4.2.5, o poder discriminativo das mesmas foi avaliado através dos testes referidos na mesma secção. A Tabela 7 mostra os resultados do teste de Kruskal Wallis. Os diagramas de caixa representativos da distribuição das características de acordo com a classe podem ser consultados no Anexo 1, para as três primeiras e três últimas características do ranking de Kruskal Wallis.

Tabela 7 - Teste de Kruskal Wallis. O parâmetro H corresponde à estatística de Kruskal Wallis.

Característica	Ranking de Kruskal Wallis	H	Graus de liberdade	Significância
Dur_QS	1	3759,973	1	0,000
Max_neg	2	3644,908	1	0,000
D_esq	3	3624,919	1	0,000
Dur_RS	4	3314,859	1	0,000
Ar_abs	5	2745,910	1	0,000
Dur_QR	6	2102,299	1	0,000
BPM	7	2036,728	1	0,000
Dif_RS	8	1721,671	1	0,000
Ar_neg	9	1436,315	1	0,000
N_val	10	1227,257	1	0,000
Relacao_Amps	11	942,303	1	0,000
Amp_Q	12	899,440	1	0,000
Amp_S	13	706,475	1	0,000
Ar_pos	14	465,426	1	0,000
Razao_RS	15	406,712	1	0,000
D_dir	16	308,741	1	0,000
Relacao_Durs	17	75,662	1	0,000
Razao_RQ	18	29,208	1	0,000
Dif_RQ	19	3,579	1	0,059
Amp_R	20	3,024	1	0,082

Na Figura 38 está representado o gráfico de dispersão para as duas melhores características do ranking de Kruskal Wallis, que compreende todas as instâncias dos cinco sinais utilizados neste trabalho. É de salientar que os batimentos cardíacos normais apresentam uma distribuição de características bastante homogénea, enquanto que nas ESV é observada uma grande dispersão, fruto da grande diversidade de morfologias existente.

Verifica-se também uma sobreposição relativamente grande das duas classes, o que significa que a discriminação das mesmas não será simples.




Figura 38 - Gráfico de dispersão de todas as instâncias dos cinco sinais utilizados neste trabalho, considerando as duas primeiras características do ranking de Kruskal Wallis. N - Normal. ESV - Extra-Sístole Ventricular.

A análise da Tabela 7 permite inferir acerca do poder discriminativo de cada característica apenas de uma forma individual. Não é válido assumir que um subconjunto que inclua as primeiras características do ranking de Kruskal Wallis é ideal. Este facto é verificado pelos resultados da pesquisa exaustiva de subconjuntos de características, os quais são descritos a seguir.

Os resultados desta pesquisa foram diferentes de acordo com o critério de seleção utilizado.

Para o critério *Consistency Subset Eval*, o subconjunto ótimo de características obtido foi: AmpQ, Max_neg, Dur_QS, Dif_RQ, BPM, Ar_abs.

Por outro lado, para o critério *Cfs Subset Eval*, o subconjunto ótimo obtido foi: Max_neg, Dur_RS, Dif_RS, Ar_abs, Ar_neg, D_esq, D_dir.

Ambos os critérios de seleção utilizados na pesquisa deram origem a subconjuntos de características que não possuíam unicamente características de lugares cimeiros do ranking de Kruskal Wallis.

4.3.4 - Teste de parâmetros para os algoritmos de classificação

Inicialmente foram feitos testes extensos com diferentes combinações de graus de *kernels* polinomiais e parâmetros C para utilizar em SVM, e testes de parâmetros K para utilizar em KNN. Nestes testes utilizou-se o método *leave-one-out* descrito na secção 4.2.6 e consideraram-se as 20 características iniciais tal como referido na mesma secção. Os resultados estão no Anexo 2.

Como os resultados do teste inicial referido acima conduziram a resultados diversificados consoante o sinal utilizado para teste, utilizou-se o método *10-fold cross validation* também descrito na secção 4.2.6 para realizar a classificação. Desta forma, para cada combinação de parâmetros dos algoritmos obtiveram-se valores únicos para as medidas de desempenho da classificação. O primeiro critério considerado na avaliação da melhor combinação de parâmetros dos algoritmos foi o valor de SE da classificação produzida.

Numa fase inicial, verificou-se qual o melhor valor de K a utilizar no algoritmo KNN. O valor de K=1 foi o que produziu melhores resultados, como se pode verificar na Tabela 8.

Tabela 8 - Análise do efeito da variação do parâmetro K no desempenho da classificação pelo algoritmo KNN, através do método *10-fold cross validation*. O valor mais elevado de sensibilidade é verificado para K=1 e encontra-se assinalado.

K	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F1
1	99,67	98,59	99,86	99,24	0,989
3	99,63	98,26	99,88	99,34	0,988
5	99,59	97,98	99,88	99,33	0,987
7	99,58	98,03	99,86	99,24	0,986
9	99,51	97,70	99,84	99,09	0,984

Portanto, nos passo seguintes de classificação utilizar-se-á o valor de K=1 para o algoritmo KNN.

Seguidamente, verificou-se qual a melhor tipologia para o *kernel* a utilizar na classificação por SVM, mantendo o parâmetro C constante e igual a 1. Os resultados estão representados na Tabela 9, onde se verifica que o melhor *kernel* é polinomial de grau 4.

Tabela 9 - Análise do efeito da utilização de diferentes *kernels* no desempenho da classificação por SVM utilizando o método *10-fold cross validation*. Em cada um dos casos, o valor do parâmetro C é mantido constante e igual a 1. O valor mais elevado de sensibilidade é verificado para o *kernel* polinomial de grau 4 e encontra-se assinalado.

Kernel	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F1
Linear	99,45	97,56	99,79	98,81	0,982
Polinomial grau 2	99,62	98,36	99,85	99,15	0,988
Polinomial grau 3	99,64	98,68	99,81	98,96	0,988
Polinomial grau 4	99,62	98,73	99,78	98,78	0,988
Polinomial grau 5	99,63	98,64	99,80	98,92	0,988

Uma vez obtido o melhor *kernel* para o algoritmo SVM, foi necessário descobrir qual o valor do parâmetro C que conduz a melhores resultados de classificação em conjunto com o *kernel* selecionado. Os resultados estão representados na Tabela 10.

Tabela 10 - Verificação do melhor valor do parâmetro C a aplicar considerando um *kernel* polinomial de grau 4, utilizando uma classificação baseada no método *10-fold cross validation*. O valor mais elevado de SE é verificado em dois casos. Portanto, desses dois casos selecionou-se aquele em que se verificou um valor de especificidade mais elevado, que é para C = 0.1 (assinalado).

C	Taxa de sucesso (%)	SE (%)	SP (%)	Precisão (%)	F1
0.01	99,63	98,59	99,82	99,01	0,988
0.1	99,65	98,73	99,81	98,96	0,988
1	99,62	98,73	99,78	98,78	0,988
10	99,65	98,68	99,82	99,01	0,988
100	99,56	98,45	99,76	98,68	0,986
1000	99,50	98,45	99,69	98,27	0,984

Como se pode verificar na tabela acima, o melhor valor para o parâmetro de C é 0.1. Verificou-se um empate nos valores de SE, por isso recorreu-se também à verificação do parâmetro SP.

4.3.5 - Teste de características e classificação

Depois da seleção dos melhores parâmetros para os algoritmos de classificação, efetuou-se o teste de características devido à diferença de resultados obtidos na secção 4.3.3. Foram testados 4 subconjuntos de características: o subconjunto resultante da pesquisa com o critério *Consistency Subset Eval*; o subconjunto resultante da pesquisa com o critério *Cfs Subset Eval*; as 6 primeiras características do ranking de Kruskal Wallis; as 7 primeiras do ranking de Kruskal Wallis. Os resultados deste teste com o recurso ao algoritmo SVM estão representados na Tabela 11.

Tabela 11 - Teste de diferentes subconjuntos de características com o algoritmo SVM, com um *kernel* polinomial de grau 4 e parâmetro $C=0.1$. Encontra-se também representado o resultado da classificação com todas as características, para efeitos comparativos. A classificação foi efetuada recorrendo ao método *10-fold cross validation*.

	Taxa de sucesso (%)	SE(%)	SP(%)	P+ (%)	F1
Todas as características	99,65	98,73	99,81	98,96	0,988
Resultado de <i>Cfs Subset Eval</i> - 7 características	99,60	98,26	99,85	99,15	0,987
Resultado de <i>Consistency Subset Eval</i> - 6 características	99,15	95,87	99,74	98,55	0,972
7 primeiras características do ranking de K. Wallis	98,75	92,95	99,80	98,85	0,958
6 primeiras características do ranking de K. Wallis	97,72	86,00	99,84	98,97	0,920

Analisando a tabela acima, verifica-se que o maior valor de sensibilidade é verificado para a utilização do subconjunto de 7 características resultante da pesquisa com o critério *Cfs Subset Eval*, não considerando a eficácia verificada para utilização de todas as características. Efetuou-se o mesmo teste para o algoritmo KNN, cujos resultados estão representados na Tabela 12.

Tabela 12 - Teste de diferentes subconjuntos de características com o algoritmo KNN, com $K=1$. Encontra-se também representado o resultado da classificação com todas as características, para efeitos comparativos. A classificação foi efetuada recorrendo ao método *10-fold cross validation*.

	Taxa de sucesso (%)	SE(%)	SP(%)	P+ (%)	F1
Todas as características	99,67	98,59	99,86	99,24	0,989
Resultado de <i>Cfs Subset Eval</i> - 7 características	99,63	98,45	99,85	99,15	0,988
Resultado de <i>Consistency Subset Eval</i> - 6 características	99,58	98,54	99,76	98,68	0,986
7 primeiras características do ranking de K. Wallis	99,62	98,59	99,80	98,92	0,988
6 primeiras características do ranking de K. Wallis	99,51	98,12	99,76	98,68	0,984

Através da análise da tabela acima, verifica-se que para o caso do algoritmo KNN os resultados não são tão concretos. Apesar de se verificarem também bons resultados para o

melhor caso verificado com SVM, existem outros subconjuntos que apresentam bons resultados, até melhores em termos de sensibilidade. São os casos do subconjunto das 7 primeiras características do ranking de K. Wallis e do subconjunto de 6 características resultante da pesquisa com o critério *Consistency Subset Eval*. Porém, como os resultados para o caso do algoritmo SVM foram bastantes expressivos e como para o algoritmo KNN a diferença de desempenho entre os diferentes casos não é crítica, o subconjunto ótimo de características considerado foi o subconjunto de 7 características resultantes da pesquisa com o critério *Cfs Subset Eval*.

Depois de selecionado o subconjunto ótimo de características, foi realizada uma tentativa de melhorar o desempenho da classificação através do método *Principal Component Analysis*. Este método forneceu a matriz de correlação entre as diferentes características do subconjunto ótimo, e através da transformação dos dados forneceu também 5 novos atributos (*Principal Components*) que resultaram de uma combinação linear dos atributos do subconjunto de origem. A matriz de correlação das características está representada na Tabela 13.

Tabela 13 - Matriz de correlação entre as diferentes características do subconjunto ótimo selecionado.

	Max_neg	Dur_RS	Dif_RS	Ar_abs	Ar_neg	D_esq	D_dir
Max_neg	1	-0,31	-0,51	-0,34	0,79	0,39	-0,03
Dur_RS	-0,31	1	0,36	0,75	-0,39	-0,21	0,52
Dif_RS	-0,51	0,36	1	0,64	-0,46	0,26	-0,4
Ar_abs	-0,34	0,75	0,64	1	-0,3	-0,18	0,34
Ar_neg	0,79	-0,39	-0,46	-0,3	1	0,31	0,07
D_esq	0,39	-0,21	0,26	-0,18	0,31	1	-0,47
D_dir	-0,03	0,52	-0,4	0,34	0,07	-0,47	1

A matriz de correlação das características revela que no subconjunto ótimo ainda existem pares de características cuja correlação é considerável, embora os casos sejam poucos. De seguida apresenta-se a comparação entre a classificação com o subconjunto de características selecionado previamente e a classificação com os *Principal Components* obtidos neste passo do trabalho. A comparação é feita recorrendo a cada um dos algoritmos de classificação e está representada na Tabela 14.

Tabela 14 - Comparação entre a classificação com as características do subconjunto ótimo e a classificação com os *Principal Components*, recorrendo aos algoritmos KNN com parâmetro K=1 e SVM com *kernel* polinomial de grau 4 e parâmetro C=0.1. A classificação foi efetuada recorrendo ao método *10-fold cross validation*.

		Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F1
KNN	Subconjunto ótimo	99,60	98,26	99,85	99,15	0,987
	<i>Principal Components</i>	95,93	73,56	99,98	99,87	0,847
SVM	Subconjunto ótimo	99,63	98,45	99,85	99,15	0,988
	<i>Principal Components</i>	99,11	96,81	99,52	97,35	0,971

Através da análise da Tabela 14, verifica-se uma diminuição clara na qualidade do desempenho de ambos os classificadores quando a classificação é realizada com os *Principal Components*. Este facto sugere que o subconjunto de características selecionado previamente já se encontra suficientemente otimizado e que a capacidade discriminativa do mesmo não pode ser melhorada. De entre a grande diversidade de características existente inicialmente, conseguiu-se então encontrar um conjunto de 7 características com propriedades bastante discriminativas, que permitiu aos classificadores registar desempenhos comparáveis àqueles registados quando era utilizado o conjunto global de características.

Uma vez finalizada toda a etapa de otimização de características, efetua-se um último teste, baseado no método *leave-one-out*, descrito na secção 4.2.6. Utilizando este método, cada sinal isolado constitui o conjunto de teste, sendo os restantes sinais utilizados para treino. Desta forma são obtidos resultados realistas. Os resultados deste teste estão representados na Tabela 15 e Tabela 16 para os algoritmos KNN e SVM, respetivamente.

Tabela 15 - Classificação baseada no método *leave-one-out*, utilizando o algoritmo KNN com K=1.

Sinais	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F1
Teste de mit119	100,00	100,00	100,00	100,00	1,000
Teste de mit213	99,83	99,09	99,89	98,64	0,989
Teste de mit215	97,41	62,20	99,22	80,31	0,701
Teste de mit223	83,09	26,69	95,66	57,80	0,365
Teste de mit233	53,91	97,95	37,57	36,80	0,535
Média	86,85	77,19	86,47	74,71	0,718

Tabela 16 - Classificação baseada no método *leave-one-out*, utilizando o algoritmo SVM, com um kernel polinomial de grau 4 e $C=0.1$.

Sinais	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F1
Teste de mit119	100,00	100,00	100,00	100,00	1,000
Teste de mit213	99,93	99,09	100,00	100,00	0,995
Teste de mit215	98,36	69,51	99,84	95,80	0,806
Teste de mit223	87,99	35,59	99,67	96,00	0,519
Teste de mit233	79,10	99,88	71,37	56,47	0,721
Média	93,08	80,81	94,18	89,65	0,808

Os resultados evidenciados nas Tabelas 15 e 16 permitem tirar duas conclusões principais. A utilização do *10-fold cross validation*, apesar de não repetir instâncias nos conjuntos de treino e teste, inclui instâncias dos sinais que vão ser classificados no conjunto de treino, e desta forma o modelo de classificação conduz a melhores resultados. A segunda conclusão é que o algoritmo SVM apresenta uma capacidade de generalização consideravelmente melhor do que o algoritmo KNN.

No caso do sinal mit119, os resultados atingem máximos em todos os parâmetros de eficácia para os dois algoritmos, uma vez que este sinal é caracterizado por ESV uniformes, e além disso não regista a ocorrência de outros tipos de batimentos cardíacos que não sejam normais ou ESV. Portanto, este sinal apresenta dois grupos bem definidos em que a classificação se torna simples. Relativamente ao teste dos sinais mit213 e mit233, os valores de sensibilidade são ainda bastante satisfatórios. Porém, no caso do sinal mit233 verificam-se valores mais baixos de especificidade, com especial destaque para o caso em que o algoritmo de classificação utilizado é o KNN. Por último, no caso do teste dos sinais mit215 e mit223 os valores de sensibilidade verificados foram extremamente baixos, mantendo-se os valores de especificidade elevados. Estes valores de sensibilidade baixos devem-se a erros de classificação em que ESV são classificadas como normais, o que pode ser explicado por uma grande presença de ESV com morfologias semelhantes a batimentos normais de entre as múltiplas formas de ESV observadas nestes sinais.

Na Tabela 17 apresenta-se a comparação de desempenho na deteção de ESV entre o primeiro algoritmo construído para este fim e o classificador SVM, que foi o classificador que apresentou melhores resultados.

Tabela 17 - Comparação de desempenho entre primeiro algoritmo detetor de ESV e o classificador SVM, que apresentou melhores resultados em relação ao KNN.

	Taxa de sucesso (%)	Se (%)	Sp (%)	P+ (%)	F1
Primeiro algoritmo	96,99	81,61	98,87	90,15	0,854
Classificador SVM	93,08	80,81	94,18	89,65	0,808

Os resultados são algo surpreendentes. O primeiro algoritmo simples, que utiliza apenas uma característica, apresenta melhores resultados do que um algoritmo de classificação complexo que utiliza várias características. Além disso, o desempenho do primeiro algoritmo

considera as falhas de detecção dos complexos QRS, enquanto que o desempenho do classificador SVM é calculado tendo em consideração apenas os batimentos cardíacos detetados.

Há que salientar um facto que pode ter sido crítico na obtenção destes resultados de desempenho. No caso do algoritmo SVM, foi efetuada uma extração de características que considerou a localização de picos Q e S. Possíveis erros de detecção de picos Q e S podem ter influenciado as características extraídas de forma negativa, não permitindo uma distinção suficientemente robusta entre as duas classes. Por outro lado, o primeiro algoritmo considera apenas as localizações dos picos R, e estes encontram-se anotados na base de dados utilizada, o que permitiu quantificar os erros de detecção. Apesar de terem sido falhadas detecções de alguns picos R, apenas um pico foi detetado incorretamente em um dos sinais. Por considerar apenas as localizações de picos R, o primeiro algoritmo é menos sujeito a erros de cálculo de parâmetros, neste caso apenas o parâmetro BPM.

Outra consideração a fazer é que os parâmetros escolhidos para o algoritmo SVM podem não ser aqueles que conduzem a melhores resultados. Os testes efetuados não consideraram a combinação de *kernels* polinomiais de grau diferente de 4 com parâmetros C diferentes de 1. Ao considerarem-se também estas combinações, poder-se-ia obter eventualmente um classificador SVM mais eficaz. Além disso, não foram considerados os *kernels* RBF, que são os mais utilizados em estudos reportados na literatura para esta aplicação específica, como já referido [24-26]. A utilização desta tipologia de *kernels* poderia eventualmente conduzir a melhores resultados.

4.4 - Resumo

Neste capítulo foram apresentadas as metodologias utilizadas neste trabalho e os resultados obtidos. Os resultados obtidos permitiram tirar conclusões relativamente à qualidade dos métodos utilizados e das estratégias de detecção produzidas. Essas inferências, por sua vez, permitem tirar conclusões gerais acerca do trabalho desenvolvido e indicar alguns desenvolvimentos futuros. As conclusões gerais e perspetivas futuras são apresentadas a seguir, na última passagem deste documento.

Capítulo 5

Conclusões gerais e perspectivas futuras

Este trabalho consistiu fundamentalmente em desenvolver um algoritmo integral de deteção de ESV, e posteriormente desenvolver e aplicar métodos de extração de características para se verificar o desempenho da classificação de batimentos cardíacos operada por algoritmos bastante referenciados na literatura - KNN e SVM - e poder fazer comparações com o algoritmo construído.

Os resultados, apesar de constituírem uma surpresa, com o primeiro algoritmo construído a apresentar uma eficácia superior à dos classificadores, podem não corresponder à realidade pelas razões já referidas na secção 4.3.5. Porém, é evidente que o algoritmo construído apresenta um grande potencial na deteção de ESV, e a sua única limitação é que nem todas as ESV apresentam prematuridade. Por isso, um desenvolvimento futuro pode ser a inclusão de mais um parâmetro poderoso para integrar a lógica de deteção.

Em relação aos algoritmos de classificação, os resultados sugerem que os parâmetros escolhidos para os classificadores podem não ser adequados, embora tenham sido escolhidos com base no resultado de um procedimento de seleção. De facto, era esperado um melhor desempenho dos classificadores, visto que as características foram submetidas a um processamento extenso, cuja meta foi a obtenção de um subconjunto consideravelmente mais reduzido que o inicial, sendo o mais discriminativo possível. Por isso, como desenvolvimento futuro sugere-se a experimentação do conjunto de características ótimo obtido neste trabalho com todas as combinações possíveis de parâmetros para SVM e KNN, ou até mesmo com outros algoritmos de classificação.

Referências

Referências Bibliográficas

- [1] G. J. Tortora and B. Derrickson, *Principles of Anatomy and Physiology*, 13th ed. John Wiley and Sons, Inc., 2012.
- [2] R. R. Seeley, T. D. Stephens, and P. Tate, *Anatomia e Fisiologia*. Lusociência, 2007.
- [3] C. Spiers, "The Normal 12-Lead Ecg," *British Journal of Anaesthetic and Recovery Nursing*, vol. 4, no. 04, pp. 12-15, 2003.
- [4] P. R. Kowey, "Ambulatory Electrocardiographic Recording," *Circulation*, vol. 108, no. 5, p. 31e-33, Aug. 2003.
- [5] S. Mittal, C. Movsowitz, and J. S. Steinberg, "Ambulatory External Electrocardiographic Monitoring: Focus on Atrial Fibrillation," *Journal of the American College of Cardiology*, vol. 58, no. 17, pp. 1741-1749, 2011.
- [6] L. SÖRNMO and P. LAGUNA, "Electrocardiogram (ECG) Signal Processing."
- [7] P. L. MD, R. O. B. MD, D. L. M. M. FACC, and D. P. Z. MD, *Braunwald's Heart Disease: A Textbook of Cardiovascular Medicine, Single Volume, 8e (Heart Disease (Braunwald))*, 8th ed. Saunders, 2007.
- [8] A. Pérez-Silva and J. Merino, "Frequent ventricular extrasystoles: significance, prognosis and treatment."
- [9] S. Talbot, "Measuring ventricular extrasystoles," *Journal of Electrocardiology*, vol. 8, no. 4, pp. 325-331, 1975.
- [10] D. Cuesta-Frau, M. O. Biagetti, R. A. Quinteiro, P. Micó-Tormos, and M. Aboy, "Unsupervised classification of ventricular extrasystoles using bounded clustering algorithms and morphology matching," *Medical & Biological Engineering & Computing*, vol. 45, no. 3, pp. 229-239, Nov. 2006.
- [11] E. P. Boas and H. Levy, "Extrasystoles of clinical significance," *American Heart Journal*, vol. 11, no. 3, pp. 264-272, 1936.
- [12] S. Talbot, "Prognostic importance of ventricular extrasystoles in acute myocardial infarction.," *Postgraduate medical journal*, vol. 53, no. 616, p. 69, 1977.
- [13] R. Vishnubhotla, "Pre-processing of ECG signals for ambulatory use," *NIU Engineering review Journal*, vol. 2, 2009.

- [14] S. A. Chouakri, F. Bereksi-Reguig, S. Ahmaidi, and O. Fokapu, "Wavelet denoising of the electrocardiogram signal based on the corrupted noise estimation," in *Computers in Cardiology, 2005*, 2005, pp. 1021-1024.
- [15] M. Kania, M. Fereniec, and R. Maniewski, "Wavelet denoising for multi-lead high resolution ECG signals," *Measurement science review*, vol. 7, no. 4, pp. 30-33, 2007.
- [16] B. U. Kohler, C. Hennig, and R. Orglmeister, "The principles of software QRS detection," *Engineering in Medicine and Biology Magazine, IEEE*, vol. 21, no. 1, pp. 42-57, 2002.
- [17] Jiapu PAN and Willis J. TOMPKINS, "A Real-Time QRS Detection Algorithm," *IEEE Transactions On Biomedical Engineering*, vol. BME-32, no. 3, 1985.
- [18] K. Narayana and A. B. Rao, "Wavelet based QRS detection in ECG using MATLAB," *Innovative Systems Design and Engineering*, vol. 2, no. 7, pp. 60-69, 2011.
- [19] J. P. M. de Sá, *Pattern Recognition: Concepts, Methods and Applications*, 1st ed. Springer, 2001.
- [20] Y. Sun, K. L. Chan, S. M. Krishnan, and D. N. Dutt, "Unsupervised classification of ECG beats using a MLVQ neural network," in *Engineering in Medicine and Biology Society, 2000. Proceedings of the 22nd Annual International Conference of the IEEE, 2000*, vol. 2, pp. 1387 -1390 vol.2.
- [21] M. Lagerholm, C. Peterson, G. Braccini, L. Edenbrandt, and L. Sornmo, "Clustering ECG complexes using Hermite functions and self-organizing maps," *Biomedical Engineering, IEEE Transactions on*, vol. 47, no. 7, pp. 838-848, 2000.
- [22] B. R. Ribeiro, A. M. Marques, J. H. Henriques, and M. A. Antunes, "Premature ventricular beat detection by using spectral clustering methods," in *Computers in Cardiology, 2007*, 2007, pp. 149-152.
- [23] I. Christov, I. Jekova, and G. Bortolan, "Premature ventricular contraction classification by the Kth nearest-neighbours rule," *Physiological measurement*, vol. 26, p. 123, 2005.
- [24] V. Chudacek, M. Petrik, G. Georgoulas, M. Cepek, L. Lhotska, and C. Stylios, "Comparison of seven approaches for holter ECG clustering and classification," in *Engineering in Medicine and Biology Society, 2007. EMBS 2007. 29th Annual International Conference of the IEEE, 2007*, pp. 3844-3847.
- [25] T. Yingthawornsuk, "Classification of Cardiac Arrhythmia via SVM," in *2nd International Conference on Biomedical Engineering and Technology IPCBEE, 2012*, vol. 34.
- [26] A. Gharaviri, F. Dehghan, M. Teshnelab, and H. Abrishami Moghaddam, "Comparison of neural network, ANFIS, and SVM classifiers for PVC arrhythmia detection," in *Machine Learning and Cybernetics, 2008 International Conference on*, 2008, vol. 2, pp. 750-755.

- [27] J. A. Nasiri, M. Sabzekar, H. S. Yazdi, M. Naghibzadeh, and B. Naghibzadeh, "Intelligent Arrhythmia Detection Using Genetic Algorithm and Emphatic SVM (ESVM)," 2009, pp. 112-117.
- [28] J. D. Gibbons and Gibbons, *Nonparametric Statistics: An Introduction*, 1st ed. Sage Publications, Inc., 1992.
- [29] I. H. Witten and E. Frank, *Data Mining: Practical Machine Learning Tools and Techniques, Second Edition*, 2nd ed. Morgan Kaufmann, 2005.
- [30] C. J. . Burges, "A tutorial on support vector machines for pattern recognition," *Data mining and knowledge discovery*, vol. 2, no. 2, pp. 121-167, 1998.

Referências Sitiográficas

(I) ynabubbles. Ecg lecture. SlideShare [Internet]. [cited 2012 Jan 24]; Available from: <http://www.slideshare.net/ynabubbles/ecg-lecture>

(II) Electrocardiogram [Internet]. [cited 2012 Jan 25]. Available from: <http://www.fpnotebook.com/CV/EKG/>

(III) Medical Dictionary [Internet]. [cited 2012 Jan 28]. Available from: <http://medicaldictionary.thefreedictionary.com/>

(IV) "Rahul Gladwin Dotcom", n.d. <http://www.rahulgladwin.com/noteblog/miscellaneous/random-usmle-facts-volume-10-5.php>

(V) "MIT-BIH Arrhythmia Database", n.d. <http://www.physionet.org/physiobank/database/mitdb/>

(VI) "AHA Database", n.d. <http://www.cardiacscience.com/resources/glossary-of-terms/aha-database.htm>

(VII) "Association for the Advancement of Medical Instrumentation", n.d. <http://www.aami.org/>

ANEXOS

Anexo 1

Diagramas de caixa para as três melhores e três piores características do ranking de Kruskal Wallis.

Para as três melhores características:




Figura 39 - Diagrama de caixa para a distribuição da característica: Duração Q-S. Classe 0-batimento normal; Classe 1-ESV.




Figura 40 - Diagrama de caixa para a distribuição da característica: Máximo Negativo. Classe 0-batimento normal; Classe 1-ESV.




Figura 41 - Diagrama de caixa para a distribuição da característica: Declive de subida do complexo QRS. Classe 0-batimento normal; Classe 1-ESV.

Para as três piores características:




Figura 42 - Diagrama de caixa para a distribuição da característica: Amplitude do pico R. Classe 0-batimento normal; Classe 1-ESV.




Figura 43 - Diagrama de caixa para a distribuição da característica: Diferença de amplitudes entre o pico R e o pico Q. Classe 0-batimento normal; Classe 1-ESV.




Figura 44 - Diagrama de caixa para a distribuição da característica: Razão entre a amplitude do pico R e a amplitude do pico Q. Classe 0-batimento normal; Classe 1-ESV

Anexo 2

Resultado de testes extensos com diferentes combinações de graus de *kernels* polinomiais e parâmetros C para utilizar em SVM, e testes de parâmetros K para utilizar em KNN, utilizando o método *leave-one-out*.

Tabela 18 - Teste das diferentes combinações de graus de *kernels* polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit119 para teste e os restantes para treino.

Kernel	C	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F
Linear	1	100,00	100,00	100,00	100,00	1,000
	10	100,00	100,00	100,00	100,00	1,000
	100	100,00	100,00	100,00	100,00	1,000
	1000	100,00	100,00	100,00	100,00	1,000
Polinomial, grau 2	1	100,00	100,00	100,00	100,00	1,000
	10	100,00	100,00	100,00	100,00	1,000
	100	100,00	100,00	100,00	100,00	1,000
	1000	100,00	100,00	100,00	100,00	1,000
Polinomial, grau 3	1	100,00	100,00	100,00	100,00	1,000
	10	100,00	100,00	100,00	100,00	1,000
	100	96,78	100,00	95,85	87,40	0,933
	1000	76,50	100,00	69,73	48,74	0,655
Polinomial, grau 4	1	100,00	100,00	100,00	100,00	1,000
	10	95,37	100,00	94,04	82,84	0,906
	100	96,58	100,00	95,59	86,72	0,929
	1000	100,00	100,00	100,00	100,00	1,000
Polinomial, grau 5	1	98,19	100,00	97,67	92,50	0,961
	10	98,84	100,00	98,51	95,07	0,975
	100	100,00	100,00	100,00	100,00	1,000
	1000	100,00	100,00	100,00	100,00	1,000




Figura 45 - Variação de SE com o parâmetro C na classificação por SVM, para *kernels* polinomiais de grau 1 a 5, utilizando o sinal mit119 para teste e os restantes para treino.

Tabela 19 - Teste dos diferentes valores de K na classificação por KNN, utilizando o sinal mit119 para teste e os restantes para treino.

K	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F
1	100,00	100,00	100,00	100,00	1,000
3	100,00	100,00	100,00	100,00	1,000
5	100,00	100,00	100,00	100,00	1,000
7	100,00	100,00	100,00	100,00	1,000
9	100,00	100,00	100,00	100,00	1,000




Figura 46 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit119 para teste e os restantes para treino.

Tabela 20 - Teste das diferentes combinações de graus de *kernels* polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit213 para teste e os restantes para treino.

Kernel	C	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F
Linear	1	99,93	99,09	100,00	100,00	0,995
	10	99,93	99,09	100,00	100,00	0,995
	100	99,93	99,09	100,00	100,00	0,995
	1000	99,93	99,09	100,00	100,00	0,995
Polinomial, grau 2	1	99,93	99,09	100,00	100,00	0,995
	10	99,93	99,09	100,00	100,00	0,995
	100	99,93	99,09	100,00	100,00	0,995
	1000	99,93	99,09	100,00	100,00	0,995
Polinomial, grau 3	1	99,93	99,09	100,00	100,00	0,995
	10	99,93	99,09	100,00	100,00	0,995
	100	99,90	98,63	100,00	100,00	0,993
	1000	99,69	97,72	99,85	98,17	0,979
Polinomial, grau 4	1	99,93	99,09	100,00	100,00	0,995
	10	99,90	98,63	100,00	100,00	0,993
	100	99,69	97,72	99,85	98,17	0,979
	1000	99,69	97,72	99,85	98,17	0,979
Polinomial, grau 5	1	99,69	97,72	99,85	98,17	0,979
	10	99,69	97,72	99,85	98,17	0,979
	100	99,65	97,72	99,81	97,72	0,977
	1000	99,65	97,72	99,81	97,72	0,977




Figura 47 - Variação de SE com o parâmetro C na classificação por SVM, para *kernels* polinomiais de grau 1 a 5, utilizando o sinal mit213 para teste e os restantes para treino.

Tabela 21 - Teste dos diferentes valores de K na classificação por KNN, utilizando o sinal mit213 para teste e os restantes para treino.

K	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F
1	99,86	98,63	99,96	99,54	0,991
3	99,86	98,63	99,96	99,54	0,991
5	99,86	98,63	99,96	99,54	0,991
7	99,90	98,63	100,00	100,00	0,993
9	99,90	98,63	100,00	100,00	0,993




Figura 48 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit213 para teste e os restantes para treino.

Tabela 22 - Teste das diferentes combinações de graus de *kernels* polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit215 para teste e os restantes para treino.

Kernel	C	Taxa de sucesso (%)	SE (%)	SP (%)	P+(%)	F
Linear	1	97,50	56,71	99,59	87,74	0,689
	10	98,22	68,90	99,72	92,62	0,790
	100	98,39	73,17	99,69	92,31	0,816
	1000	97,44	73,17	98,69	74,07	0,736
Polinomial, grau 2	1	98,42	71,95	99,78	94,40	0,817
	10	98,30	76,83	99,41	86,90	0,816
	100	60,44	73,78	59,76	8,59	0,154
	1000	31,29	69,51	29,33	4,80	0,090
Polinomial, grau 3	1	97,92	81,10	98,78	77,33	0,792
	10	57,76	73,17	56,97	8,02	0,145
	100	39,47	75,61	37,62	5,85	0,109
	1000	14,31	70,12	11,44	3,90	0,074
Polinomial, grau 4	1	66,06	71,34	65,79	9,66	0,170
	10	45,15	77,44	43,50	6,57	0,121
	100	15,88	67,07	13,26	3,81	0,072
	1000	72,28	73,17	72,23	11,90	0,205
Polinomial, grau 5	1	45,15	73,78	43,68	6,30	0,116
	10	21,92	65,85	19,67	4,03	0,076
	100	61,01	70,12	60,54	8,35	0,149
	1000	61,01	70,12	60,54	8,35	0,149




Figura 49 - Variação de SE com o parâmetro C na classificação por SVM, para *kernels* polinomiais de grau 1 a 5, utilizando o sinal mit215 para teste e os restantes para treino.

Tabela 23 - Teste dos diferentes valores de K na classificação por KNN, utilizando o sinal mit215 para teste e os restantes para treino

K	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F
1	95,03	60,98	96,78	49,26	0,545
3	94,91	57,32	96,84	48,21	0,524
5	92,47	55,49	94,37	33,58	0,418
7	91,43	54,88	93,31	29,61	0,385
9	89,65	53,66	91,49	24,44	0,336

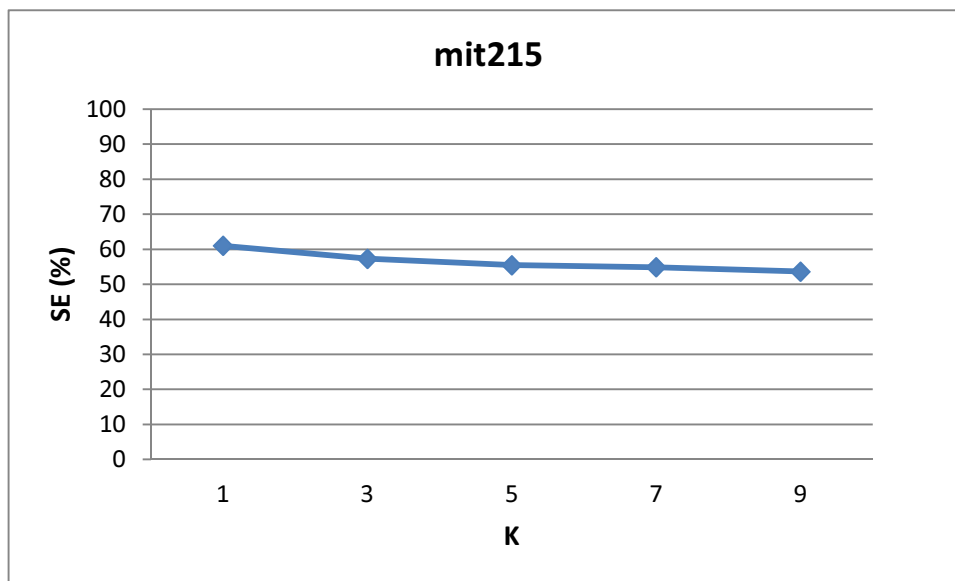


Figura 50 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit215 para teste e os restantes para treino.

Tabela 24 - Teste das diferentes combinações de graus de *kernels* polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit223 para teste e os restantes para treino.

Kernel	C	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F
Linear	1	85,87	25,00	99,43	90,77	0,392
	10	87,41	39,41	98,11	82,30	0,533
	100	88,61	51,06	96,98	79,02	0,620
	1000	85,06	42,58	94,52	63,41	0,510
Polinomial, grau 2	1	87,30	38,98	98,06	81,78	0,528
	10	82,63	46,82	90,60	52,62	0,496
	100	50,23	48,73	50,57	18,01	0,263
	1000	51,81	72,88	47,12	23,50	0,355
Polinomial, grau 3	1	77,14	43,64	84,61	38,72	0,410
	10	49,58	39,19	51,89	15,37	0,221
	100	38,76	69,70	31,87	18,57	0,293
	1000	32,70	83,26	21,44	19,11	0,311
Polinomial, grau 4	1	47,76	39,19	49,67	14,79	0,215
	10	36,29	68,01	29,23	17,64	0,280
	100	32,86	83,05	21,67	19,11	0,311
	1000	34,36	62,71	28,05	16,26	0,258
Polinomial, grau 5	1	35,52	63,56	29,27	16,69	0,264
	10	32,20	83,26	20,82	18,99	0,309
	100	31,70	66,95	23,84	16,38	0,263
	1000	31,70	66,95	23,84	16,38	0,263

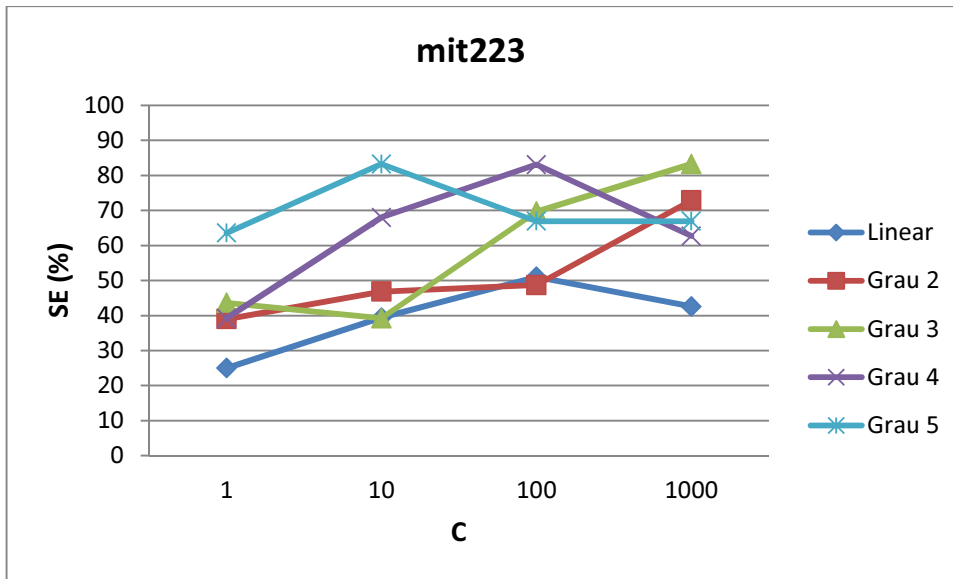


Figura 51 - Variação de SE com o parâmetro C na classificação por SVM, para kernels polinomiais de grau 1 a 5, utilizando o sinal mit223 para teste e os restantes para treino.

Tabela 25 - Teste dos diferentes valores de K na classificação por KNN, utilizando o sinal mit223 para teste e os restantes para treino

K	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F
1	57,68	28,60	64,16	15,10	0,198
3	72,47	27,54	82,48	25,95	0,267
5	75,52	23,52	87,11	28,91	0,259
7	78,30	18,86	91,55	33,21	0,241
9	49,27	36,86	52,03	14,62	0,209




Figura 52 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit223 para teste e os restantes para treino.

Tabela 26 - Teste das diferentes combinações de graus de *kernels* polinomiais com parâmetros C na classificação por SVM, utilizando o sinal mit233 para teste e os restantes para treino.

Kernel	C	Taxa de sucesso (%)	SE (%)	SP (%)	P+ (%)	F
Linear	1	68,13	99,88	56,35	45,93	0,629
	10	75,73	99,88	66,77	52,74	0,690
	100	79,62	99,88	72,09	57,05	0,726
	1000	80,33	99,88	73,08	57,93	0,733
Polinomial, grau 2	1	77,20	99,88	68,78	54,29	0,703
	10	76,39	99,88	67,67	53,41	0,696
	100	68,69	99,76	57,16	46,36	0,633
	1000	62,65	98,55	49,33	41,93	0,588
Polinomial, grau 3	1	73,84	99,88	64,18	50,86	0,674
	10	71,33	99,28	60,96	48,56	0,652
	100	68,98	98,19	58,14	46,54	0,632
	1000	52,90	94,34	37,52	35,92	0,520
Polinomial, grau 4	1	69,60	98,67	58,81	47,07	0,637
	10	68,82	97,35	58,23	46,38	0,628
	100	47,91	95,42	30,28	33,69	0,498
	1000	38,45	95,06	17,44	29,94	0,455
Polinomial, grau 5	1	68,75	98,07	57,87	46,36	0,630
	10	46,64	95,90	28,35	33,19	0,493
	100	38,39	95,90	17,04	30,03	0,457
	1000	38,39	95,90	17,04	30,03	0,457




Figura 53 - Variação de SE com o parâmetro C na classificação por SVM, para *kernels* polinomiais de grau 1 a 5, utilizando o sinal mit233 para teste e os restantes para treino.

Tabela 27 - Teste das diferentes combinações de graus de *kernels* polynomial com parâmetros C na classificação por KNN, utilizando o sinal mit233 para teste e os restantes para treino.

K	Taxa de sucesso (%)	SE (%)	SP (%)	P+(%)	F
1	60,14	97,11	46,42	40,22	0,569
3	66,89	99,04	54,96	44,94	0,618
5	75,08	99,40	66,06	52,08	0,684
7	79,06	99,16	71,60	56,45	0,719
9	81,96	99,04	75,63	60,13	0,748




Figura 54 - Variação de SE para diferentes valores de K na classificação por KNN, utilizando o sinal mit233 para teste e os restantes para treino.