

Extração de Parâmetros do Sinal ECG para Diagnóstico de Patologias

Renan Tadeu Vieira Costa

Trabalho realizado sob a orientação de

Prof. João Paulo Teixeira

Prof. Thaís Winkert

Prof. Aline Gesualdi Manhães

Mestrado em Engenharia Industrial

Outubro de 2019

Extração de Parâmetros do Sinal ECG para Diagnóstico de Patologias

Dissertação de Mestrado em Engenharia Industrial
Escola Superior de Tecnologia e Gestão
Instituto Politécnico de Bragança

Renan Costa

Outubro de 2019

Declaro que o trabalho descrito neste relatório é da minha autoria e é da minha vontade que o mesmo seja submetido a avaliação.

Renan Tadeu Vieira Costa

Agradecimentos

Todo esses momentos e realizações não teriam sentido sem o agradecimento aos meus pais Aline e Ramilton, que foram acima de tudo companheiros nessa caminhada, aconselhando na hora certa e provendo tudo que me foi necessário, e nisso me considero um privilegiado.

Ao meu irmão Ramon, que me acompanhou e ajudou sempre que necessário.

A minha namorada e companheira de estudos Suellen, que sempre esteve ao meu lado para não deixar eu desistir.

Meus familiares, que de alguma forma sempre torceram por mim e permaneceram presentes ao meu lado.

Meus amigos da vida e de curso, que transformaram meu dia a dia em algo mais simples e prazeroso, embarcando comigo nessa aventura de estudar em outro país.

Agradeço ao meu orientador Prof. João Paulo Teixeira, por todo o seu empenho ao longo desta jornada. A minha orientadora Prof. Thaís Winkert, por toda paciência e ajuda nos desafios encontrados. E a Prof. Aline Gesualdi Manhães por sua disponibilidade e conselhos.

Por fim, agradeço a todos que direta ou indiretamente contribuíram para este projeto.

Resumo

O eletrocardiograma (ECG) é um exame médico que registra os fenômenos elétricos resultantes da atividade cardíaca e uma das principais ferramentas diagnósticas da prática clínica cardiológica. Esses registros, em sua maioria, apresentam ruídos que incluem componentes de baixa e alta frequência que interferem na identificação e classificação dos parâmetros presentes no sinal. Neste trabalho, o objetivo principal é a extração das características presentes no ECG de forma eficiente, através da elaboração de algoritmo no software MATLAB. Com a utilização de técnicas de pré-processamento, foram feitas análises de diferentes filtros digitais e técnicas de suavização, como cancelamento da componente DC e remoção da linha de base, com finalidade da redução das interferências geradas na captação do sinal.

Com o sinal suavizado, foram implementados no projeto ferramentas para o reconhecimento de eventos do ECG. O sinal foi elevado ao quadrado e derivado, para evidenciar o pico mais visível, o pico R. Com a localização desse pico, foi aplicado um limiar adaptativo, baseado no algoritmo de Pan-Tompkins, para resultados não tão lineares. Os outros picos, P-Q-S-T, foram encontrados a partir da procura de máximos e mínimos em regiões padrões do sinal. O algoritmo desenvolvido obteve uma taxa de acerto de 98,09% na identificação do complexo QRS e de 96,29% das demais ondas.

O presente trabalho implementou técnicas baseadas em redes neurais, com a utilização de uma rede do tipo *feedforward* e o algoritmo *backpropagation* para classificar os sinais e seus respectivos parâmetros gerados. O melhor resultado, dentre os testados, foi com a utilização da função de treinamento do gradiente descendente com momento, com taxa de acerto de 66,67% na identificação de patologias.

Palavras-chave: Eletrocardiograma, Processamento de sinal, Redes neurais.

Abstract

The electrocardiogram (ECG) is a medical exam that records electrical phenomena resulting from cardiac activity. Moreover, it is one of the main diagnostic tools of clinical cardiac practice. Most of these records contain noise that includes low and high frequency components that interfere with the identification and classification of the parameters present in the signal. In this work, the main objective is to extract the characteristics present in the ECG efficiently, through the elaboration of algorithm in the MATLAB software. Analyzes of different digital filters and smoothing techniques were performed using preprocessing techniques, such as cancellation of the DC component and removal of the baseline, with the aim of reducing the interference generated in signal capture.

After smoothing the signal, ECG event recognition tools were implemented in the project. The signal was squared and derived to highlight the most visible peak, the R-peak. By the location of this peak, an adaptive threshold based on the Pan-Tompkins algorithm was applied for not-so-linear results. The other peaks, P-Q-S-T, were found from the search for highs and lows in standard signal regions. The developed algorithm obtained a hit rate of 98.09% in the QRS complex identification and 96.29% of the other waves.

The present work implemented techniques based on neural networks using a feedforward network and the backpropagation algorithm to classify the signals and their respective generated parameters. The use of the descending gradient training function with momentum presenting a hit rate of 66.67% in identifying pathologies, was the best result among those tested.

Keywords: Electrocardiogram, Signal Processing, Neural Networks.

Conteúdo

1. Introdução	7
1.1. Objetivos	8
1.2. Organização do documento	9
2. Fundamentos Teóricos	10
2.1. Fisiologia do coração	10
2.1.1. Estrutura interna	12
2.1.2. Circulação.....	13
2.1.3. A contração cardíaca	14
2.1.4. Ciclo cardíaco.....	15
2.2 Eletrocardiograma	16
2.2.1. Derivações	18
2.3. Arritmias cardíacas.....	22
2.3.1. Arritmias por perturbação da condução	23
2.3.2. Arritmias rápidas por excitação aumentada	26
2.4 Artefatos no Eletrocardiograma.....	27
2.4.1. Interferências presentes no ECG	28
3. Transformada Wavelet.....	30
3.1. Transformada de Fourier	30
3.3. Transformada Wavelet contínua.....	32
3.4. Wavelet discreta	35
3.4.1. Coeficiente de aproximação e detalhe.....	35
3.5. Wavelet-mãe.....	37
3.5.1. wavelet de Haar.....	37
4. Redes Neurais Artificiais	40
4.1. Aprendizagem de máquinas	40
4.2. O que é um rede Neural?	41
4.4. Tipos de funções de ativação	43
4.5. Topologias das redes neurais artificiais.....	45
4.5.1. Redes não-recorrentes com camada única.....	45
4.5.2. Redes não-recorrentes com múltiplas camadas	46
4.5.3. Redes recorrentes	47
4.6. Tipos de treinamentos	47
4.6.1. Aprendizagem Supervisionada.....	48

4.6.2.	Aprendizagem Não-supervisionada	48
4.7.	Redes Multilayer Perceptron	49
4.7.1.	Backpropagation.....	49
4.7.2.	A arquitetura de rede	50
5.	Materiais e Métodos	52
5.1.	Banco de dados.....	52
5.2.	Pré-processamento	52
5.2.1.	O sinal	53
5.2.2.	Cancelamento da componente DC	55
5.2.3.	Remoção da Linha de base.....	55
5.2.4.	Remoção do Ruído	55
5.2.5.	Decomposição e Recomposição Wavelet.....	57
5.3.	Identificação dos parâmetros.....	58
5.3.1.	Método Lopes.....	58
5.3.2.	Método Pan-Tompkins	59
5.3.3.	Método Magalhães	60
5.4.	Classificação dos Sinais	61
5.4.1.	Redes Neurais.....	61
6.	Aplicações e Resultados	63
6.1.	Pré-processamento	63
6.1.2.	Implementação dos métodos	63
6.1.3.	Decomposição e Recomposição Wavelet.....	67
6.1.4.	Filtros FIR	71
6.1.5.	Método proposto	73
6.2.	Extração de parâmetros do sinal de ECG.....	75
6.2.1.	Método utilizado	75
6.2.2.	Picos R	75
6.2.3.	Complexo QRS	81
6.2.4.	Picos P e T.....	81
6.3.	Janelas Pop-up.....	82
6.3.1.	Picos P e T.....	85
6.4.	Classificação dos sinais	87
6.4.1.	Parâmetros de entrada	87
6.4.2.	Matriz de Entrada.....	88
6.4.3.	Divisão das matrizes.....	89
6.4.4.	Tipologia, arquitetura e treino da RNA.....	90

7. Conclusão e Trabalhos futuros	95
Referências Bibliográficas	97
ANEXO I	100

Lista de Tabelas

Tabela 1. Parâmetros usados no processo de filtragem.	79
Tabela 2. Resultados da implementação do método com a Falha de detecção.	80
Tabela 3. Representação em segundos do limiar para identificação dos picos Q, S, P e T.	82
Tabela 4. Identificação das ondas P e T com ajuste de filtragem e limiar.	86
Tabela 5. Taxa de acerto dos das curvas presentes no ECG.....	86
Tabela 6. Arritmias encontradas nos 48 sinais do MIT-BIH.....	88
Tabela 7. Representação do Tipo e Tamanho das configurações das matrizes.....	90
Tabela 8. Categoria de cada sinal na matriz teste.....	91
Tabela 9. Resultados da configuração 1, indicando em verde os diagnósticos corretos.	92
Tabela 10. Resultados da configuração 2, indicando em verde os diagnósticos corretos.	92
Tabela 11. Melhor resultado encontrado na classificação dos sinais.	93

Lista de Figuras

Figura 2.1: Localização do coração no corpo humano (Netter, 2000).	10
Figura 2.2: Corte do pericárdio e da parede do ventrículo direito, mostrando as divisões do pericárdio e as camadas da parede cardíaca (Applegate, 2012).	12
Figura 2.3: Anatomia do coração com artérias e outras estruturas. Fonte: Disponível em: https://static.todamateria.com.br/upload/57/73/5773c7021c1ab-arterias.jpg	13
Figura 2.4: Estruturas do complexo estimulante do coração. Fonte: Applegate, 2012	15
Figura 2.5: O ciclo do coração. Fonte: Applegate, 2012.....	16
Figura 2.6: Registro de um eletrocardiograma normal. Fonte: Shea, 2013.....	18
Figura 2.7: Triângulo de Einthoven. Fonte: Disponível em: https://www.researchgate.net/profile/Marcella_Moro2/publication/316981885/figure/fig2/AS:494800349483008@1494981004967/Figura-2-Triangulo-de-Einthoven_W640.jpg	19
Figura 2.8: Formas de ondas típicas de um ECG. Fonte: Applegate, 2012	19
Figura 2.9: Derivações precordiais. Fonte: http://www.acm.org.br/acm/acamt/documentos/curso_clinica_medica_2018/eletrocardiograma_normal.pdf	22
Figura 2.10: Doença do Nódulo Sinusal. Fonte: Medwave, 2010.....	23
Figura 2.11: Bloqueio de Primeiro Grau. Fonte: Aguiar, 2006.....	24
Figura 2.12: Bloqueio de Segundo Grau. Fonte: Aguiar, 2006.....	25
Figura 2.13: Bloqueio de Terceiro Grau. Fonte: Aguiar, 2006.	25
Figura 2.14: Fibrilação Auricular. Fonte: Aguiar, 2006.....	26
Figura 2.15: Flutter Auricular. Fonte: Aguiar, 2006.	27
Figura 2.16: Extrassístole. Fonte: Medwave, 2010.....	27
Figura 3.1: Escala de Wavelets. Fonte: Misiti, 2001.....	34
Figura 3.2: Compressão de wavelets. Fonte: Misiti, 2001	34
Figura 3.3: Decomposição de um sinal nível 1. Fonte: Misiti, 2001.....	36
Figura 3.4: Árvore de decomposição de um sinal com vários níveis. Fonte: Misiti, 2001	36
Figura 3.5: Reconstrução do sinal a partir dos coeficientes da Wavelet. Fonte: Misiti, 2001 ...	37
Figura 3.6: Função wavelet Haar. Fonte: Haar, 1910.	38
Figura 3.7: Função wavelet chapéu mexicano. Fonte: Misiti, 2001.....	38
Figura 3.8: Funções wavelet Daubechies. Fonte: Misiti, 2001	39
Figura 3.9: Funções wavelets Coiflets e Symmlets. Fonte: Misiti, 2001	39
Figura 4.1: Modelo geral do neurônio artificial. Fonte: Haykin, 2001.	42
Figura 4.2: Funções de ativação mais utilizadas. (a) Função Limiar. (b) Função Linear por partes. (c) Função Sigmóide com parâmetro de inclinação variável. Fonte: Haykin, 2001.....	45
Figura 4.3: Rede não-recorrente com camada única. Fonte: Haykin, 2001.	46
Figura 4.4: Rede não-recorrente multicamada com camada oculta. Fonte: Haykin, 2001.....	46
Figura 4.5: Rede recorrente com neurônios ocultos. Fonte: Haykin, 2001.....	47
Figura 4.6: Processo de aprendizado das Redes neurais	48
Figura 5.1: Sinal original “sel103m.mat” do base de dados MIT-BIH.	53
Figura 5.2: Sinal original após FFT.	54
Figura 5.3: Seção dos dois primeiros ciclos cardíacos do sinal original.	54
Figura 6.1: Seção dos dois primeiros ciclos cardíacos após o uso do método Lopes.	64
Figura 6.3: Seção dos dois primeiros ciclos cardíacos após o uso do método Pan-Thompkins..	65
Figura 6.4: Sinal suavizado do método Pan-Thompkins.....	65
Figura 6.6: Coeficiente de aproximação com uso da wavelet Haar de (a)nível 1, (b) nível 2, (c) nível 3.....	68

Figura 6.7: Coeficiente de aproximação com uso da wavelet Daubechies de (a)nível 1, (b) nível 2, (c) nível 3.	68
Figura 6.8: Coeficiente de aproximação com uso da wavelet Symmlets de (a)nível 1, (b) nível 2, (c) nível 3.	69
Figura 6.9: Coeficiente de aproximação com uso da wavelet Coiflets de (a)nível 1, (b) nível 2, (c) nível 3.	69
Figura 6.10: Recomposição nas escalas 1, 2, 3 e 4.	70
Figura 6.11: Decomposição do sinal original de 4 níveis.	71
Figura 6.12: Comparação entre os tipos de filtragem do sinal original no processo de remoção do ruído.	72
Figura 6.13: Método proposto.	73
Figura 6.14: Comparação entre o sinal original e o sinal suavizado.	74
Figura 6.15: Comparação entre o sinal original e o filtrado.	74
Figura 6.16: Sinal 103m no domínio da frequência.	75
Figura 6.17: Sinal 103m elevado ao quadrado.	76
Figura 6.18: Erro de identificação com o passar do tempo (a) em 100m, com intervalo de 60 segundos (b).	78
Figura 6.19: Erro de identificação com o passar do tempo (a) em 112m, com intervalo de 60 segundos (b).	78
Figura 6.20: Erro de identificação com o passar do tempo (a) em 116m, com intervalo de 60 segundos (b).	78
Figura 6.21: Esquemático da interface oferecida ao usuário para ajustes.	83
Figura 6.22: Sinal 103m reduzido com presença da janela de decisão.	83
Figura 6.23: Janelas de decisão para alterar os valores dos filtros.	84
Figura 6.24: Sinal 103m reduzido, com marcação dos picos e presença do pop-up de decisão.	84
Figura 6.25: Janelas de decisão para alterar os valores dos limiares.	85
Figura 6.26: Exemplificação da Matriz de entrada.	89

1. Introdução

Este projeto, Extração de Parâmetros do Sinal do Eletrocardiograma (ECG) para Diagnóstico de Patologias, foi desenvolvido no âmbito da unidade curricular Dissertação do Mestrado de Engenharia Industrial do Instituto Politécnico de Bragança.

A cardiologia consiste em uma das mais importantes áreas de estudo e pesquisa das ciências biomédicas, e também, as doenças relacionadas ao coração são as que mais matam no mundo. De acordo com a OMS em seu último relatório de 2018 sobre a saúde mundial, as doenças cardiovasculares totalizaram 17,9 milhões de mortes, representando 44% de todas as mortes por doenças não transmissíveis no mundo (World Health Statistics, 2018). Assim, um sistema de auxílio ao diagnóstico robusto e eficaz pode proporcionar um avanço na detecção prematura de patologias.

Uma ferramenta de diagnóstico amplamente utilizada e essencial na prática clínica de cardiologia é o eletrocardiograma (ECG) (Yeh, 2008). Considerada uma das ferramentas não invasivas mais comuns usadas para o diagnóstico de doenças cardíacas pelos médicos. Extremamente versátil e barato, permite registrar a atividade elétrica produzida pela ativação miocárdica, sendo o seu traçado constituído por várias deflexões causadas pela ativação, despolarização e repolarização das células cardíacas. (Maleki, 2017).

A partir dos dados obtidos no ECG e em seu sinal elétrico gerado, este projeto busca, como objetivo principal, a extração confiável dos parâmetros contidos no sinal. Como parte do processo de extração, inicialmente o sinal captado é alisado, ou seja, é necessária uma redução das interferências encontradas no processo de captação do mesmo. A partir desta etapa, os parâmetros podem ser identificados com uso de técnicas de processamento de sinais, evidenciando os dados importantes e cruciais para a análise cardiológica.

Com auxílio de ferramentas de inteligência artificial, os parâmetros encontrados puderam ser classificados de acordo com a presença ou não de patologias. Uma classificação importante, já que os sinais utilizados no projeto são oriundos de exames do tipo Holter, caracterizado pela permanência dos eletrodos em contato com o paciente por um período de 24 horas. Esse é um exame incômodo para a maioria dos pacientes, e uma

análise efetiva dos pontos do eletrocardiograma que contém algum tipo de arritmia cardíaca podem proporcionar uma não repetição do procedimento.

Já são encontrados na literatura e em uso eficaz, alguns algoritmos que fazem esse tipo de identificação dos parâmetros, como o desenvolvido por (Pan; Tompkins, 1985; Yeh; Wang, 2008; Haddadi et al., 2014), alternando entre o uso de limiares adaptativos de varredura do sinal e mais recentemente o uso de wavelets, para identificação e separação do sinal. Porém, todos eles têm como principal desafio o desenvolvimento confiável do sistema de auxílio ao diagnóstico de patologias relacionadas ao coração. Assim esse trabalho visa desenvolver uma ferramenta que proporcione ao operador uma análise o mais fiel possível dos acontecimentos captados a partir do exame de ECG.

Com foco no processamento digital de sinal, o projeto incorpora tarefas que proporcionam um estudo dos sinais de eletrocardiograma e outras ferramentas de inteligência artificial.

1.1. Objetivos

O projeto possui um objetivo principal, a extração das características em conjunto com os parâmetros encontrados no ECG. Essas características podem ser determinadas como as curvas P-QRS-T e seus respectivos picos. E dois objetivos secundários, mas primordiais e importantes em todo processo. O pré-processamento do sinal de ECG obtido de um banco de dados disponível online, e a classificação desse sinal com o auxílio de inteligência artificial.

O primeiro objetivo, o pré-processamento do sinal captado, é um dos mais importantes do processo. Para uma boa identificação dos parâmetros e sua classificação, o sinal deve ser o mais livre de ruídos possível, ou seja, o sinal captado contém diversas interferências que podem prejudicar o processo como um todo. A redução desse ruído proporciona um alisamento do sinal, evitando picos indesejados e reduzindo a presença de falsos positivos e negativos dos picos, parâmetro importante para a extração dos dados.

O segundo, a extração de características do sinal de ECG, é o foco principal do projeto. Devido à morfologia das ondas, condições fisiológicas e a presença de ruídos, o

desafio nesse projeto é a elaboração de um algoritmo robusto, que tenha uma boa taxa de acerto dos parâmetros presentes no sinal, identificando de maneira correta as curvas P-QRS-T para uma posterior classificação de patologias.

E o último, uma vertente que vem ganhando força nos estudos recentes, é a utilização de inteligência artificial para a classificação de sinais biológicos. O uso de redes neurais que se baseiam em um banco de dados para classificações futuras. Assim, o projeto visa a utilização dos dados fornecidos pelo algoritmo de extração para classificar as patologias presentes nos sinais adquiridos.

1.2. Organização do documento

O documento está organizado basicamente em três partes. Uma introdução com o referencial teórico encontrado na literatura e que serve de base para o desenvolvimento do projeto. A segunda parte, o material usado em conjunto com os métodos aplicados. E a última, a apresentação dos resultados e sua discussão.

A introdução está dividida em três capítulos, em que serão apresentados conceitos relacionados a fisiologia do coração, a utilização das transformadas wavelets e das redes neurais artificiais. O próximo capítulo após essa introdução, é o que apresenta os materiais e métodos utilizados nesse projeto. Com a citação do banco de dados utilizado, os métodos de filtragem, extração e classificação do sinal. E os últimos capítulos se reservam a demonstrar a aplicabilidade dos métodos e também a elaboração do método proposto pelo projeto. Com a apresentação dos resultados e discussão com os trabalhos relacionados, a conclusão é elaborada e apresentada como parte final do documento.

2. Fundamentos Teóricos

2.1. Fisiologia do coração

O coração se compara à uma bomba hidráulica, seus músculos geram a força necessária para o sangue circular por todos os tecidos corporais, função fundamental para a sobrevivência. O sangue leva nutrientes e oxigênio aos tecidos e remove os resíduos metabólicos (Applegate, 2012).

Ele é o órgão responsável pelo bombeamento do sangue através do corpo. Muscular, com cavidades, situado na porção central da cavidade torácica, entre o osso esterno e a coluna vertebral, abraçado pelos pulmões e acima do diafragma. Disposto obliquamente e seu ápice mais inclinado para o lado esquerdo do plano mediano, visualizado na Figura 2.1 (Eládio, 2015).

O coração tem o tamanho aproximado de um punho fechado e com um peso entre 230 a 340 gramas, variando com o tamanho e o gênero da pessoa. Em homens, pode variar entre 280 a 340 gramas, com aproximadamente 0,45% do peso corporal, em mulheres, 230 a 280 gramas, com 0,40% do peso corporal (Drake, 2014). O número de batimentos cardíacos realizados por minuto está, normalmente, entre 60 a 80 vezes por minuto em pessoas sem doenças ou anormalidades cardíacas (Guyton, 2002).

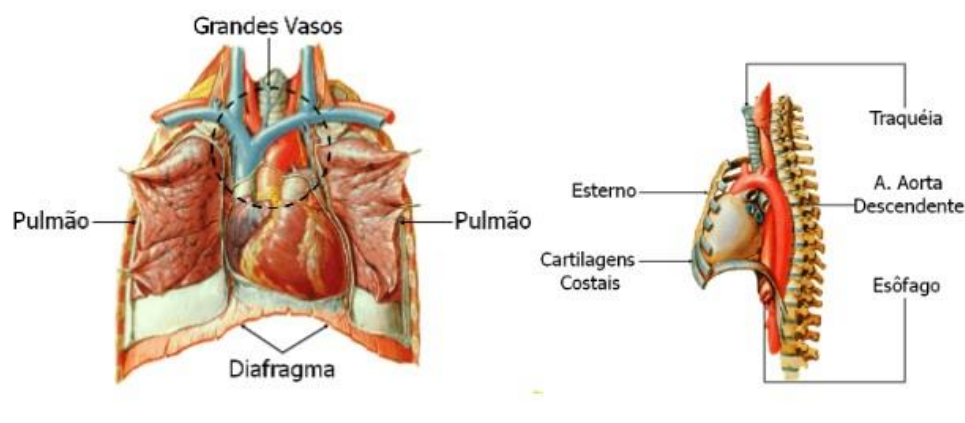


Figura 2.1: Localização do coração no corpo humano (Netter, 2000).

O coração consegue bombear o sangue devido à força de contração do músculo cardíaco, o miocárdio. Tecido composto de células musculares estriadas especializadas que diferem do tecido muscular esquelético, por exemplo. Essa diferença está na capacidade de contrair-se e relaxar-se rapidamente, algo que não acontece nos músculos esqueléticos (Eládio, 2015).

Internamente ao miocárdio, há uma camada interna chamada endocárdio, correspondente à membrana que reveste externamente o coração. Camada de tecido epitelial que proporciona uma superfície lisa e escorregadia ao coração, facilitando assim seu movimento ininterrupto (Walker, 2002).

E uma camada externa ao coração chamada por pericárdio, que corresponde a uma estrutura sacolar fibrosa localizada em torno do coração e das raízes dos grandes vasos. Este é dividido em dois componentes, o pericárdio fibroso e o pericárdio seroso. O pericárdio fibroso consiste em uma camada externa de tecido conjuntivo denso, e o pericárdio seroso é fino e consiste em duas partes (Figura 2.2) (Applegate, 2012).

As duas camadas do pericárdio seroso podem ser determinadas como:

- A camada parietal, que é responsável pelo revestimento interno.
- A camada visceral, que adere ao coração e forma sua cobertura externa. Esta camada é também denominada epicárdio.

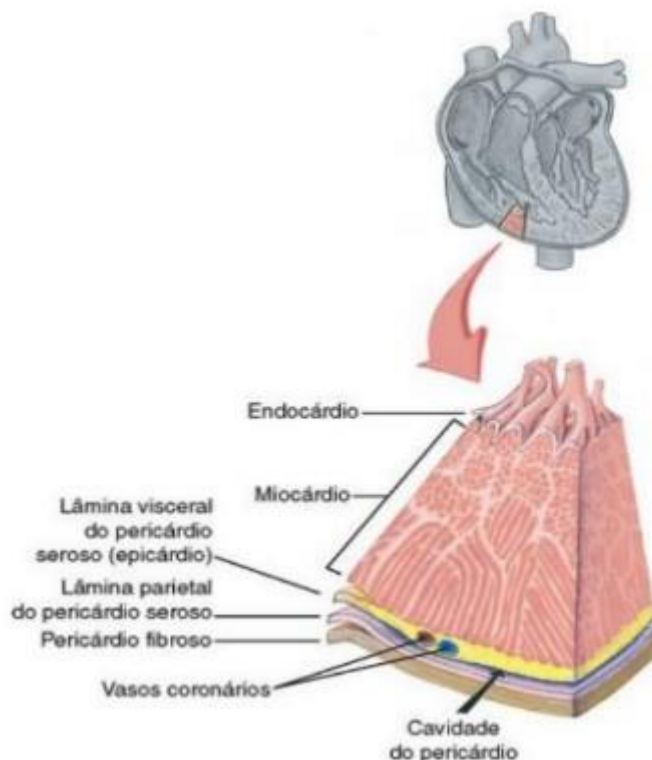


Figura 2.2: Corte do pericárdio e da parede do ventrículo direito, mostrando as divisões do pericárdio e as camadas da parede cardíaca (Applegate, 2012).

2.1.1. Estrutura interna

Internamente, o coração é dividido em quatro câmaras (dois átrios e dois ventrículos) separadas pelo septo atrioventricular (Figura 2.3). A comunicação entre átrios e ventrículos ocorre devido aos sulcos coronário, cada um com suas válvulas, que têm como objetivo impedir o retorno do sangue para os ventrículos, fazendo com que o sangue siga num único sentido. Esse fluxo é possível a partir da comunicação existente do lado esquerdo e direito do coração, controlado por válvulas que garantem o sentido correto do sangue (Eládio, 2015).

O coração possui quatro válvulas distintas (Figura 2.3). As duas válvulas atrioventriculares funcionam como entradas para os respectivos ventrículos. Do lado esquerdo, entre o átrio e o ventrículo situa-se a válvula mitral. Entre o átrio direito e o ventrículo direito situa-se a válvula tricúspide. Essas válvulas regulam a passagem do sangue entre as suas cavidades.

As outras duas, as válvulas semilunares estão situadas à saída da artéria aorta e pulmonar – Válvulas sigmoideias. Estas válvulas fecham os orifícios da aorta (ventrículo esquerdo) e da artéria pulmonar (ventrículo direito), impedindo assim o refluxo do sangue para os ventrículos (Guyton, 2002).

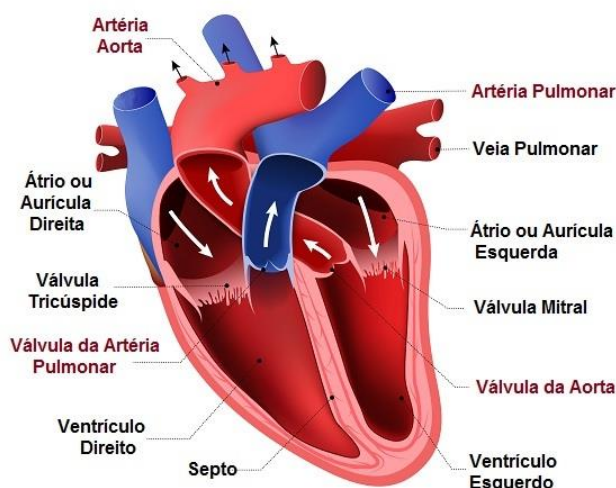


Figura 2.3: Anatomia do coração com artérias e outras estruturas. Fonte: Disponível em: <https://static.todamateria.com.br/upload/57/73/5773c7021c1ab-artérias.jpg>

2.1.2. Circulação

O coração humano apresenta duas circulações complementares – a circulação pulmonar (ou pequena circulação) e a circulação sistémica (ou grande circulação). A pequena circulação tem como função levar ao sangue aos pulmões para efetuar trocas gasosas, o dióxido carbono sai do sangue para os pulmões e acontece a entrada de oxigénio dos pulmões para o sangue. O sangue sai do ventrículo direito pela artéria pulmonar e dirigem-se para os pulmões, e regressa ao coração através das veias pulmonares que se dirigem para o átrio esquerdo.

Em seguida o sangue segue para o coração onde será bombeado sangue arterial para todo o organismo (grande circulação), os vasos sanguíneos que vão do lado esquerdo do coração para os tecidos e voltam para o lado direito (Davis, 1987).

2.1.3. A contração cardíaca

A contração cardíaca, determinada por uma sequência de contrações musculares altamente organizadas, coordenada por impulsos elétricos, das quatro câmaras do coração. Seu ciclo efetivo depende da perfeita sincronia do coração, ou seja, os átrios precisam se contrair simultaneamente seguidos pela contração dos ventrículos. As células musculares cardíacas especializadas que constituem o complexo estimulante coordenam a contração das câmaras. Essas células atuam como tecido nervoso, iniciando a distribuição dos estímulos através do miocárdio para coordenar os eventos do ciclo cardíaco (Applegate, 2012). O complexo estimulante do coração e suas estruturas são demonstrados na Figura 2.4.

O primeiro estímulo elétrico parte do nó sinoatrial, chamado de marca-passo do coração, pois determina o ritmo básico dos batimentos cardíacos. Estes conjuntos de células, através de reações químicas, geram um impulso elétrico que se propaga rapidamente através do miocárdio atrial, ocasionando a contração simultânea dos átrios. Os impulsos gerados anteriormente chegam simultaneamente ao nó átrio ventricular. Suas células conduzem impulsos de forma mais lenta, dessa forma, existe um atraso enquanto os impulsos se propagam pelo nó, possibilitando que os átrios terminem suas contrações antes dos ventrículos iniciarem as suas. Após essa etapa, os impulsos se propagam de forma rápida através do fascículo atrioventricular para os ramos do fascículo direito e esquerdo. Os ramos do fascículo se estendem ao longo dos lados direito e esquerdo do septo interventricular até o ápice, e se ramificam originando os ramos subendocárdicos de miofibras condutoras (fibras de Purkinje) que transmitem impulsos para o miocárdio. O fascículo atrioventricular, os ramos do fascículo e os ramos subendocárdicos transmitem impulsos rapidamente, ocasionando a contração simultânea dos ventrículos, dessa forma, o sangue é expelido através das válvulas semilunares para o interior do tronco pulmonar, a artéria ascendente da aorta. Após a contração, os ventrículos relaxam e o nó sino atrial inicia outro impulso desencadeando um novo ciclo cardíaco (Frazão, 2015).

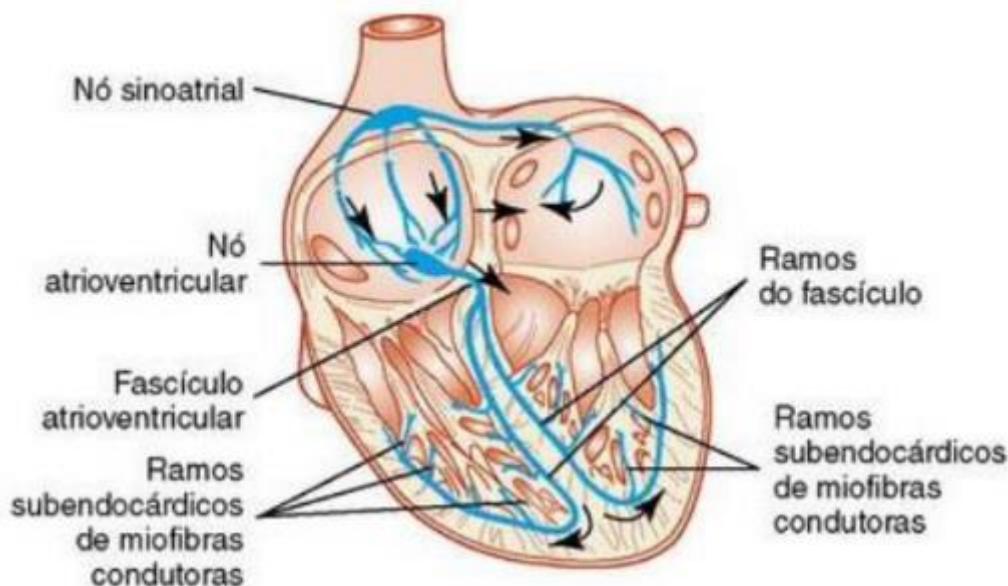


Figura 2.4: Estruturas do complexo estimulante do coração. Fonte: Applegate, 2012

2.1.4. Ciclo cardíaco

O ciclo cardíaco (Figura 2.5) é um conjunto de eventos presentes no início de um batimento até ao batimento seguinte. Neste ciclo está presente um período de relaxamento ou diástole do músculo cardíaco – miocárdio – e um período de contração ou sístole. A partir do nodo sinoatrial, onde o potencial de ação cardíaco é gerado, a corrente elétrica produzida é propagada pelos átrios através do sistema de Purkinje, provocando sua contração. Poucos milissegundos depois, o impulso atinge o nodo atrioventricular, retardando o impulso para os átrios fornecerem a passagem de sangue para os ventrículos. Após esse retardo, o impulso é propagado pelo sistema aos ventrículos contraíndo-os (Guyton; Hall, 2006). O evento mais importante, para a sobrevivência do indivíduo, no ciclo cardíaco é a Sístole ventricular, uma vez que é nessa etapa que o sangue é colocado em circulação. Assim, considera-se que o ciclo cardíaco é a ocorrência alternada sistemática de sístole ventricular e diástole ventricular (Lopes, 2010; Joana, 2004).

A duração do ciclo cardíaco normal é de 0,8 segundo com uma frequência, em média, de 75 batimentos por minuto. A sístole atrial inicia o ciclo, as valvas atrioventriculares estão abertas e os ventrículos encontram-se em diástole enquanto recebem o sangue dos átrios. Esse processo dura 0,1 segundo, logo depois, os átrios relaxam (diástole atrial) pelo restante do ciclo. Os ventrículos iniciam sua contração após

o término da fase de contração dos átrios. A sístole ventricular dura 0,3 segundo. A pressão nos ventrículos aumenta durante a contração e as valvas atrioventriculares se fecham enquanto as valvas semilunares se abrem, permitindo a passagem do sangue para o interior do tronco pulmonar e da parte ascendente da aorta. Durante essa fase do ciclo, os átrios encontram-se em diástole, se enchendo de sangue novamente (Applegate, 2012). Entretanto, quando a frequência cardíaca aumenta, a duração de cada ciclo cardíaco diminui, incluindo as fases de contração e relaxamento. A duração do potencial de ação e o período de sístole também diminuem, o que significa que em frequência muito rápida, o coração não permanece tempo suficiente relaxado para permitir o enchimento completo das câmaras cardíacas da próxima contração, caracterizando um problema (Guyton; Hall, 2006)..

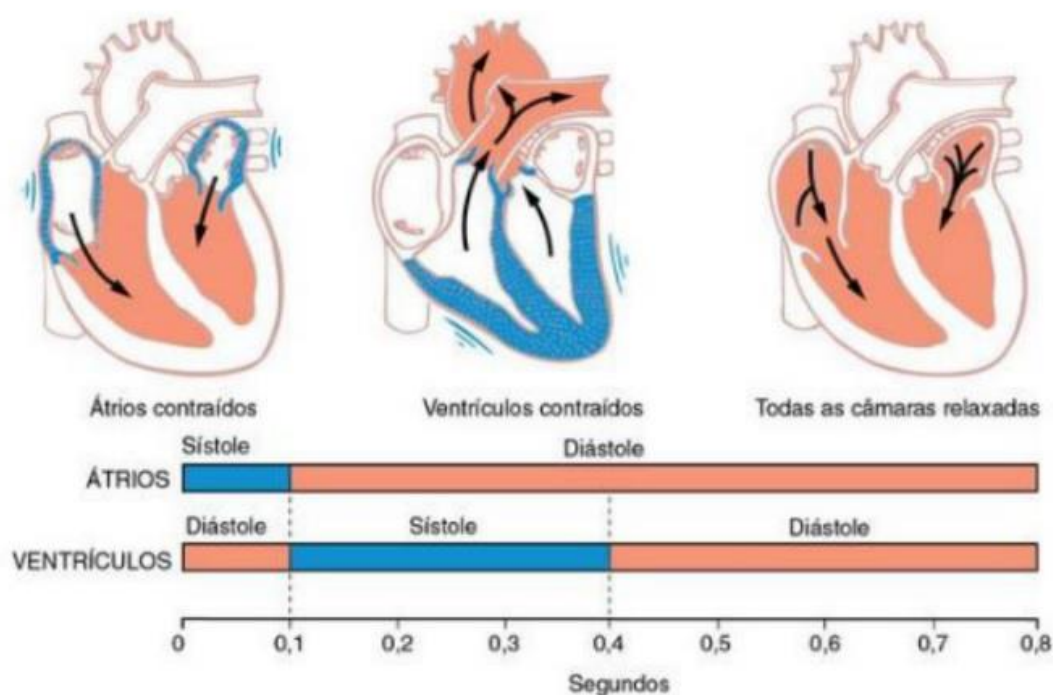


Figura 2.5: O ciclo do coração. Fonte: Applegate, 2012.

2.2. Eletrocardiograma

O eletrocardiograma (ECG) é uma ferramenta de diagnóstico amplamente utilizada e essencial na prática clínica de cardiologia (Yeh, 2008). Ele é a captação e registro dos sinais elétricos gerados pelas atividades do coração em seus ciclos cardíacos (Yeh, 2008). O eletrocardiograma é uma das ferramentas não invasivas mais comuns

usadas para o diagnóstico de doenças cardíacas pelos médicos (Maleki, 2017). Extremamente versátil e barato, permite registrar a atividade elétrica produzida pela ativação miocárdica, sendo o seu traçado constituído por várias deflexões causadas pela ativação, despolarização e repolarização das células cardíacas (Maleki, 2017).

Esta informação é obtida a partir de um aparelho, o eletrocardiógrafo ou máquina de ECG. Este aparelho é um galvanómetro, que mede correntes elétricas de baixa intensidade ou a diferença de potencial elétrico entre dois pontos. Esses registros são captados a partir de eléctrodos posicionados na pele humana.

A propagação do impulso ao longo do coração proporciona a origem a uma serie de ondas que se sobrepõem num conjunto característico – ondas P-QRS-T e, eventualmente, U (Figura 2.6).

O sinal do ECG traduz o registro das despolarizações e repolarizações em três etapas:

- Onda P: Corresponde a despolarização, ou seja, a ativação da musculatura dos átrios e suas células cardíacas. Possui uma morfologia tipicamente arredondada, de baixo potencial, com amplitude máxima de 0,25mv e duração de aproximadamente 60ms.
- Complexo QRS: Representa a despolarização ventricular, que leva a contração dos ventrículos. Formado pelas ondas Q, R e S, este complexo é maior que a onda P, pois a massa muscular apresentada pelos ventrículos é maior que a apresentada pelas aurículas. Após a ocorrência da onda P, entre 0.15 a 0.20s aproximadamente, as aurículas iniciam a sua repolarização, no momento em que se registra a ocorrência do complexo QRS.
- Onda T: Corresponde à repolarização ventricular, relaxamento do musculo ventricular. Com morfologia normalmente perpendicular e arredondada.
- Onda U: esta onda nem sempre está presente. Está relacionada com a repolarização dos músculos papilares (um tipo de músculos existentes nos ventrículos).




Figura 2.6: Registro de um eletrocardiograma normal. Fonte: Shea, 2013

2.2.1. Derivações

Um ECG é tradicionalmente composto por doze derivações, seis derivações dos membros (I, II, III, aVR, aVL, aVF), e seis derivações do tórax ou precordiais (V1 a V6). Cada derivação é basicamente constituída por um par de elétrodos que estão ligados à superfície do corpo do paciente. Estas derivações se complementam, permitindo obter a representação tridimensional da atividade cardíaca (Monteiro, 2008).

Uma forma de definir essas derivações é a partir dos trabalhos desenvolvidos de Willem Eithovem, introduzindo o conceito de vetor cardíaco no posicionamento dos elétrodos, possibilitando observar um sistema de três derivações no plano frontal. Este sistema permite o registro por meio de três conexões elétricas entre os membros do corpo do paciente. Como visualizado na Figura 2.7, o triângulo de Einthoven é formado por um triângulo equilátero, sendo os vértices os elétrodos presentes nos pulsos e perna esquerda. Em cada eixo do triângulo encontra-se presente um ponto médio, sendo uma parte positiva e outra negativa. A partir deste ponto médio são traçadas linhas perpendiculares que intersectam no centro do triângulo (Monteiro, 2008).




Figura 2.7: Triângulo de Einthoven. Fonte: Disponível em:

https://www.researchgate.net/profile/Marcella_Moro2/publication/316981885/figure/fig2/AS:494800349483008@1494981004967/Figura-2-Triangulo-de-Einthoven_W640.jpg

A Figura 2.8 e 2.8.1 ilustram essas derivações que podem ser subdivididas em dois tipos principais: bipolares e unipolares. As bipolares são caracterizadas como a combinação de dois elétrodos que registram a corrente elétrica. As unipolares são aquelas em que apenas um eletrodo contribui para o registro do ECG, o outro elétrodo funciona apenas como neutro. Outra forma de subdivisão é a partir da posição dos elétrodos, ou seja, no plano frontal (Derivações periféricas – bipolares e unipolares) e no plano horizontal (Derivações precordiais, unipolares).




Figura 2.8: Formas de ondas típicas de um ECG. Fonte: Applegate, 2012

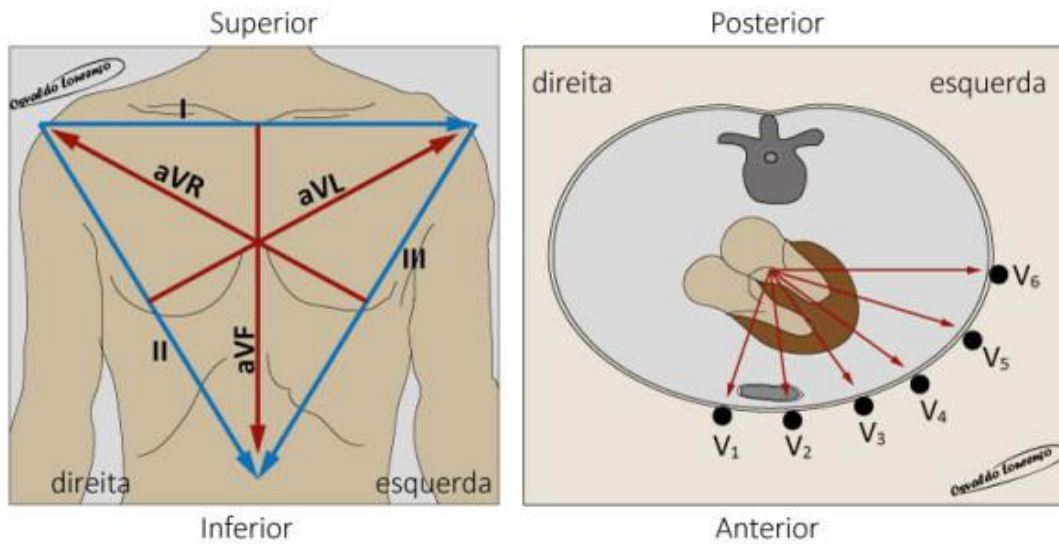


Figura 2.8.1: Derivações periféricas e no plano horizontal. Fonte: Angomed, 2014

2.2.1.1. Derivações bipolares

As derivações I, II e III são derivações bipolares que são obtidas através de dois eletrodos dos membros. A derivação I, o eletrodo negativo é conectado ao braço esquerdo e o positivo no braço direito. A derivação II, o eletrodo negativo é conectado no braço direito e na perna esquerda fica conectado o eletrodo positivo. E a III, o eletrodo negativo é conectado no braço esquerdo e o eletrodo positivo na perna esquerda.

Com base na Lei de Kirchoff, Einthoven propõe que se o valor do potencial elétrico de duas derivações for conhecido, então podemos descobrir a terceira derivação a partir da Equação 1 (Webster, 1997).

$$DII = DI + DIII$$

(Eq. 1)

2.2.1.2. Derivações unipolares

- **Derivações unipolares aumentadas**

Ao acrescentar três linhas de referência na interseção com o triângulo de Einthoven, com ângulos entre si, obtém-se as três derivações unipolares periféricas ou derivações aumentadas de Goldberger no plano frontal (Webster, 1997).

As derivações aVR (*augmented vector righ*), aVL (*augmented vector left*) e aVF (*augmented vector foot*) são chamadas derivações unipolares aumentadas uma vez que resultam da amplificação do sinal recolhido com o eletrodo positivo colocado respetivamente no braço direito, braço esquerdo e perna esquerda em relação a um eletrodo negativo criado eletronicamente (Pereira, 2015).

- **Derivações precordiais**

As derivações precordiais permitem realizar o registro dos potenciais elétricos no plano horizontal com apenas três ou cinco eletrodos. A aquisição com três eletrodos é normalmente utilizada para monitorização contínua de cabeceira. Neste caso é fixo o eletrodo negativo, o neutro e o positivo é colocado na posição precordial desejada, V1 a V6. No caso de cinco eletrodos são colocados todos os quatro eletrodos nos membros e o quinto é colocado na posição precordial desejada (Pereira, 2015).

Cada uma das derivações precordiais (Figura 2.9) têm o seu eletrodo positivo inserido num ponto específico da parede ventricular. As derivações V1 e V2 são fixadas na parede do ventrículo direito, a V3 é fixada sobre a área intermediária entre o ventrículo direito e esquerdo, a derivação V4 é fixada sobre o ápice cardíaco e as V5 e V6 são fixadas na parede do ventrículo esquerdo (Monteiro, 2008).




Figura 2.9: Derivações precordiais. Fonte:

http://www.acm.org.br/acm/acamt/documentos/curso_clinica_medica_2018/eletrocardiograma_normal.pdf

2.3. Arritmias cardíacas

Uma arritmia é um problema relacionado com o ritmo dos batimentos cardíacos. Esta perturbação pode ocorrer sob a forma de um ritmo excessivamente lento, da ausência de um ou mais batimentos ou de um número excessivo de batimentos por minuto (bpm). Em qualquer uma destas situações, quando o coração bate de forma irregular, o bombeamento de sangue para as várias partes do corpo pode ser dificultado, colocando em perigo órgãos vitais. O problema pode ocorrer sempre que o sinal elétrico que controla o batimento cardíaco é atrasado ou bloqueado, ou seja, o sinal elétrico não faz seu percurso normal anteriormente observado (Morais, 2009).

A ativação elétrica do coração, como discutido anteriormente, surge no nodo sinoatrial, entretanto, outros marca-passos, como o nodo atrioventricular, os sistemas especializados de condução e o próprio miocárdio podem iniciar a ativação elétrica. Estímulos anormais gerados tanto no nodo sinusal, ou no nodo atrioventricular, constituem os distúrbios da formação do impulso. Outra origem para a arritmia pode estar envolvida com o sistema de condução pelo qual o impulso elétrico se propaga. Alterações nessas via surgem como um bloqueio ou alterações que levam o impulso elétrico seguir por um caminho anormal, gerando uma despolarização do músculo cardíaco de forma inadequada. Há também as arritmias causadas por reentrada cíclica, como a Síndrome de WolffParkinson-White e o Flutter Atrial (Carneiro, 2012).

As arritmias cardíacas, assim como outras anormalidades cardíacas, são detectáveis através da realização de um ECG, sendo este um teste essencial no diagnóstico e monitorização (Monteiro, 2008). As arritmias são detectadas pela alteração da formação do estímulo elétrico, da condução ou pelo conjunto destes dois fatores, acarretando ao coração não contrair de maneira rítmica como de costume.

2.3.1. Arritmias por perturbação da condução

2.3.1.1. Bradicardia Sinusal

A bradicardia sinusal ocorre no nóculo sinoauricular e é caracterizada pela frequência inferior a 60 batimentos por minuto. A consequência no eletrocardiograma é uma maior distância entre os batimentos (Aguiar, 2006).

2.3.1.2. Taquicardia Sinusal

Taquicardia Sinusal é o oposto da Bradicardia Sinusal, isto é, o ritmo cardíaco apresenta-se acelerado, com uma frequência maior que 100 batimentos por minuto (existindo autores que consideram 90). Como consequência, no ECG iremos ter uma menor distância entre batimentos (Pádua, 2008).

2.3.1.3. Doença do Nóculo Sinusal

Nessa doença, o nóculo sinusal perde a sua ritmicidade, causando frequências demasiado lentas e/ou rápidas ou até mesmo pausas devido a bloqueios, observados na Figura 2.10. Também podemos ter Bradicardia alternada com Taquicardia, a esta junção denomina-se por Síndrome Bradi-taqui (Pádua, 2008).



Figura 2.10: Doença do Nóculo Sinusal. Fonte: Medwave, 2010

2.3.1.4. Taquicardia Atrial

Na arritmia taquicardia atrial, ocorre quando um foco dentro do átrio dá sinalização ou reentra no circuito local. A taquicardia é provocada pela rapidez do disparo. Esta arritmia é caracterizada por uma deformação na onda P, caracterizada por um aumento da frequência cardíaca que inicia e cessa rapidamente, esta situação pode demorar alguns minutos ou algumas horas (Aguiar, 2006).

2.3.1.5. Bloqueio Aurículo-ventricular (Bloqueio A-V)

O bloqueio A-V consiste num atraso ou interrupção da passagem do estímulo elétrico das aurículas para os ventrículos. Esta patologia pode ter diversas causas entre as quais: a inflamação da doença reumática, doença coronária e/ou a ação de alguns medicamentos (Pádua, 2008). O bloqueio AV é diagnosticado em três graus distintos e possui sua classificação de acordo com a onda P, ou seja, caracterizado pelo atraso ou bloqueio da onda.

2.3.1.5.1. Bloqueio A-V de Primeiro Grau (Bloqueio Fruste)

O bloqueio A-V de primeiro grau trata-se de um atraso, não ocorrendo verdadeiramente bloqueio (Figura 2.11). No ECG para esta patologia, o intervalo de passagem do estímulo da aurícula para o ventrículo é maior. Assim, o intervalo P-Q é maior (Aguiar, 2006).



Figura 2.11: Bloqueio de Primeiro Grau. Fonte: Aguiar, 2006

2.3.1.5.2. Bloqueio A-V de Segundo Grau (Bloqueio Incompleto)

No bloqueio A-V incompleto, às vezes o estímulo não é transmitido da aurícula para o ventrículo (Figura 2.12). No ECG, nestes episódios é observada a falta do estímulo que ativaria o ventrículo (complexo QRS), sendo o motivo para falta de pulso.



Figura 2.12: Bloqueio de Segundo Grau. Fonte: Aguiar, 2006

2.3.1.5.3. Bloqueio A-V de Terceiro Grau (Bloqueio Completo)

O Bloqueio Completo é o mais grave dos bloqueios, pois as aurículas e os ventrículos apresentam o seu próprio ritmo trabalhando separadamente. Assim, o encher e esvaziar dos ventrículos não é realizada com sucesso. No ECG é obtido uma dupla onda P, uma vez que as aurículas e os ventrículos trabalham independentemente (Figura 2.13).



Figura 2.13: Bloqueio de Terceiro Grau. Fonte: Aguiar, 2006.

2.3.2. Arritmias rápidas por excitação aumentada

2.3.2.1. Taquicardia Supraventricular

Esta patologia trata-se de um aumento do ritmo cardíaco (140 a 180 bpm) de uma forma súbita, o ritmo mais acelerado deve-se a um foco irritativo auricular. Com isso, o complexo QRS é mais estreito do que o normal (Aguiar, 2006).

2.3.2.2. Fibrilação Auricular

A Fibrilação Auricular é uma arritmia crônica e tem uma incidência proporcional à idade (aos 80 anos 10% da população tem Fibrilação Auricular) (Morais, 2009). Nessa arritmia, o nóculo A-V funciona de forma irregular, fazendo variar a frequência cardíaca entre 50 e 200 bpm. A pessoa com fibrilação auricular tem um batimento nos átrios superior ao do resto do corpo, levando a uma corrente sanguínea irregular e a formação de coágulos.

No ECG, essa arritmia é detectado por ondas P não existentes e também pela presença de ondas pequenas que causam distorção da linha isoeletrica. O complexo QRS é estreito e os intervalos RR são variáveis, exemplificados na Figura 2.14 (Aguiar, 2006).




Figura 2.14: Fibrilação Auricular. Fonte: Aguiar, 2006.

2.3.2.3. Flutter Auricular

No Flutter Auricular ocorre um movimento circular do estímulo elétrico nas aurículas superior a 300 bpm, ou seja, uma frequência atrial elevada. Esta regularidade prejudica os pacientes, pois se estes são sujeitos a um esforço, a frequência aumenta de 75 para 100 e depois para 150 bpm, causando-lhes falta de ar e cansaço (Aguiar, 2006).

A Figura 2.15 apresenta um ECG sem ondas P, um Flutter Auricular com ondas semelhantes a “dentes de serra” denominadas por ondas F e a sua frequência é de 250 a 350 bpm.




Figura 2.15: Flutter Auricular. Fonte: Aguiar, 2006.

2.3.2.4. Extrassístole Ventricular

A Extrassístole Ventricular é causada por um ou mais focos irritativos no miocárdio ventricular. No ECG essa patologia é caracterizada por um complexo QRS mais largo, prematuro e anormal, também não é precedido pela onda P auricular (Figura 2.16). Em seguida, temos uma pausa (deve-se ao enchimento dos ventrículos) até à onda P seguinte (Aguiar, 2006).




Figura 2.16: Extrassístole. Fonte: Medwave, 2010

2.4. Artefatos no Eletrocardiograma

O ruído pode ser definido como um sinal indesejado que interfere na comunicação ou medição de outro sinal (Vaseghi, 2006). Os sinais de ECG possuem normalmente grande quantidade de ruídos provenientes de diversas origens, por exemplo a interferência do campo magnético do ambiente, a respiração do paciente, o próprio eletrodo, etc (Baía, 2008). A amplitude do sinal de ECG é muito baixa, por volta de 1mVpp, portanto o sinal ECG é muito sensível a interferências.

Como a aquisição do ECG é feita através de elétrodos, faz necessário, para obtenção de um sinal digital, de conversores Analógico-Digitais. Esses conversores geram ruídos de digitalização, assim como o ruído gerado pelos circuitos amplificadores. As diferenças de potenciais dos elétrodos, denominadas potenciais de meia célula, causam uma distorção na linha de base do sinal ECG. O contato eletrodo-pele tem propriedades resistivas e também capacitivas, que vão interferir na dependência com a frequência. Movimentos também podem modificar o potencial de junção, causando distorções na medida. Outra interferência muito presente no sinal ECG é o ruído muscular, que ocorre principalmente quando o paciente não se encontra em situação de repouso (Moffa, 2001).

2.4.1. Interferências presentes no ECG

- Componente DC

É uma componente transitória que surge no primeiro instante da ocorrência de medição e tem caráter exponencial, o que torna mais difícil a sua remoção, já que se trata de um sinal não periódico. Com presença característica a frequência de 0 Hz, ou eventualmente, pode ocorrer até 0.3 Hz (Batistella, 2016).

- Interferência da frequência da rede

Esse ruído está presente na frequências de 50 Hz, utilizado como padrão na Europa e de 60 Hz no padrão americano, e seus respectivos harmônicos. Ele é causado, principalmente, pela interferência do campo magnético criado pela rede de energia elétrica ou por equipamentos que sejam alimentados por essa rede e que consumam grande quantidade de energia (Bagarrão, 2014).

- Eletromiograma

Ruído causado pela atividade elétrica dos músculos e que tem uma frequência máxima de 10 kHz (Bagarrão, 2014).

- Flutuação da linha de base

É um ruído de baixa frequência (entre 0,4 a 3 Hz) causado, principalmente, pela respiração e pelo movimento do corpo (Bagarrão, 2014).

- Interferências inerentes ao próprio eletrodo.

Ao aderir um eletrodo à pele, surge naturalmente uma tensão entre a pele e o ponto de ligação do eletrodo com o cabo de paciente. Essa tensão pode ser muito maior do que as geradas pelo coração, e soma-se às tensões presentes no corpo do paciente (Baía, 2008).

3.Transformada Wavelet

Uma função wavelet é uma “pequena onda” em formato oscilante, que possui sua energia finita concentrada num ponto e valor médio igual a zero (Rocha,2008). Sua função é proporcionar uma ferramenta de análise de fenômenos transientes, não estacionários ou variantes no tempo. Ela detém a habilidade de permitir a avaliação simultânea das componentes do sinal em intervalos não-uniformes de tempo e frequência (Burrus, 1997).

As wavelets estão sendo utilizadas em várias aplicações de comunicação como alternativa à transformada de Fourier de curta duração para análise espectral de dados não estacionários ou como uma nova ferramenta para interligar a análise no domínio do tempo e no domínio da frequência (Habibi, 1995).

3.1.Transformada de Fourier

Uma das técnicas mais populares no processamento de sinais (Wang, 2000). Desenvolvida por Jean Baptiste Joseph Fourier que prevê que a análise seja feita a partir da decomposição ou quebra da série original em outros componentes ditas sinusoidais, cada qual com uma determinada frequência – obtida a partir de uma combinação linear de harmônicos (Rocha 2008). O emprego dessa técnica é recomendado quando há a necessidade de determinar a periodicidade dos dados, em que o sinal é transformado do domínio do tempo para o domínio da frequência (Gonzales, 2000).

A transformada de Fourier (Equação 2) de uma sequência $x(n)$, que contém amostras uniformemente espaçadas de um sinal $x(t)$ contínuo no tempo de $-\infty$ a $+\infty$, é dada por:

$$X(e^{j\omega}) = \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega n}$$

(Eq. 2)

Que corresponde à transformada de Fourier de um sinal contínuo, que está baseada na integração de toda a função para o cálculo de cada frequência. Sua representação acontece no domínio da frequência e a variável independente é a frequência angular ω , que é contínua. Sendo $X(e^{j\omega})$ periódica, com período 2π (Cunha, 2013).

3.2. Análise de Fourier e Análise de Wavelet.

A análise de Fourier é usada como ponto de partida para introduzir as transformadas wavelet e como uma referência para demonstrar casos em que a análise da wavelet fornece uma caracterização mais útil dos sinais do que a análise de Fourier. A transformada de Fourier resume a semelhança entre um sinal e um sinusóide com um único número complexo. A magnitude do número complexo captura o grau em que as oscilações em uma frequência específica contribuem para a energia do sinal, enquanto o argumento do número complexo captura informações de fase. É possível observar que os coeficientes de Fourier não têm dependência de tempo. Os coeficientes de Fourier são obtidos integrando ou somando ao longo do tempo, portanto fica claro que essas informações são perdidas (Semmlow, 2004; Misiti, 2001).

Em um esforço para corrigir essa deficiência, Dennis Gabor (1946) adaptou a transformada de Fourier para analisar apenas uma pequena seção do sinal de cada vez - uma técnica chamada de janelas. A adaptação de Gabor é chamada de transformada de Fourier de curta duração (STFT). A técnica funciona escolhendo uma função de tempo, ou janela, que é essencialmente diferente de zero apenas em um intervalo finito (Castañón, 2003).

O STFT representa uma espécie de compromisso entre as visualizações baseadas em tempo e frequência de um sinal. Ele fornece algumas informações sobre quando e em que frequências um evento de sinal ocorre. No entanto, só é possível obter essas informações com precisão limitada, e essa precisão é determinada pelo tamanho da janela.

Embora o compromisso STFT entre informações de tempo e frequência possa ser útil, a desvantagem é que, depois de escolher um tamanho específico para a janela de tempo, essa janela é a mesma para todas as frequências. Muitos sinais exigem uma abordagem mais flexível - uma onde você pode variar o tamanho da janela para determinar com mais precisão o tempo ou a frequência (Misiti, 2001).

Uma das vantagens básicas no uso de wavelets é que um evento pode ser simultaneamente descrito, tanto no domínio da frequência quanto no domínio do tempo, diferentemente da Transformada de Fourier onde um evento é descrito somente no domínio da frequência ou no domínio do tempo (Ashkenazy, 2002). Esta diferença permite uma análise em multi resolução dos dados de diferentes maneiras, em diferentes escalas (Ashkenazy, 2002). Uma extensa classe de sinais biológicos pode ser analisada por este método, tal como o ECG.

As wavelets são projetadas para obter em altas frequências uma boa resolução, mas uma fraca resolução no tempo. O mesmo não ocorre em baixas frequências, onde obtém-se uma boa resolução da frequência e uma restrita resolução no tempo (Manzan, 2004).

3.3. Transformada Wavelet contínua

A transformada wavelet contínua (CWT) é uma alternativa à transformada de Fourier, superando o problema da resolução (Walker, 1999). A CWT é uma transformada que é desenvolvida separadamente em vários segmentos do sinal, e não utiliza um tamanho de janela fixo. De fato, a largura da janela da CWT varia de acordo com o espectro de frequência analisado (Figueredo, 2008).

A transformada contínua wavelet pode ser interpretada como a soma sobre todo domínio temporal do sinal multiplicado por versões escalonadas e deslocadas de uma função wavelet adequadamente escolhida, as quais originam uma série de coeficientes wavelet em função de escala (frequência) e da posição (tempo). É definida a partir de funções ortogonais, que formam uma base de funções da transformada Wavelet.

É possível verificar na Equação 3, como o somatório ao longo do tempo do produto de um dado sinal por uma dada escala deslocada por uma função *wavelet* $\Psi(t)$, denominada de *wavelet* mãe.

$$C(\text{escala}, \text{posição}) = \int f(x) \Psi(\text{escala}, \text{posição})(t) dt \quad (\text{Eq.3})$$

A transformada wavelet contínua depende de dois parâmetros a e b , que correspondem às informações de escala e tempo respectivamente (Daubechies, 1990; Misiti, 2001). A definição de uma transformada wavelet considerando um sinal contínuo é dada por:

$$F(a, b) = \int f(t) \Psi_{a, b}(t) dt \quad (\text{Eq. 4})$$

Nesta equação os parâmetros a e b variam continuamente, sendo que as funções a, b são denominadas wavelets e definidas da seguinte forma:

$$\Psi_{a, b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (\text{Eq. 5})$$

3.3.1. Parâmetros das wavelets

A análise baseada em wavelets produz um sinal no domínio do tempo-escala. Os parâmetros utilizados, como observados na Equação 5, tem como função a manipulação através dos processos de translação e dilatação. Ou seja, a translação constitui os movimentos ao longo do eixo do tempo (deslocamento), e a dilatação promove alterações na representação do sinal com o intuito de explorá-lo, no tempo e escala (Manzan, 2006).

- **Escala**

A escala de uma wavelet significa a sua extensão ou compressão. É assim introduzido um fator de escala normalmente designado pela letra a . Na Figura 3.1 é possível visualizar que quanto menor esse fator de escala, mais comprimida é a wavelet. Assim, a escala está relacionada com a frequência do sinal (Misiti, 2001).

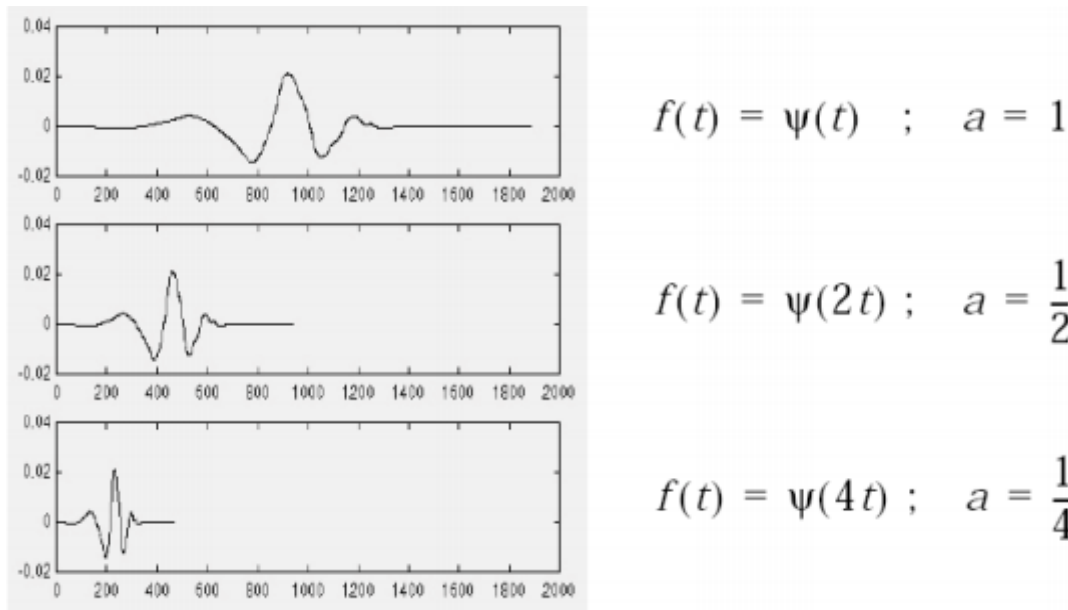


Figura 3.1: Escala de Wavelets. Fonte: Misiti, 2001

- **Deslocamento**

Deslocar a Wavelet significa simplesmente atrasá-la (Figura 3.2).




Figura 3.2: Compressão de wavelets. Fonte: Misiti, 2001

Assim, há uma correspondência entre escalas e frequências das *wavelets*, isto é:

- Para baixos $a \Rightarrow$ *wavelets* curtas \Rightarrow rápidas mudanças \Rightarrow altas frequências w .
- Para altos $a \Rightarrow$ *wavelets* longas \Rightarrow mudanças lentas \Rightarrow baixas frequências w .

3.4. Wavelet discreta

Calcular os coeficientes de Wavelet para cada escala possível é uma grande quantidade de trabalho, e é gerada uma grande quantidade de dados. Uma alternativa é abordar a transformada de wavelets na sua forma matemática discreta, dispensando os estados de difícil implementação em tempo real e suscetíveis a erros. As wavelets discretas não são transladadas nem escalonadas continuamente, mas sim em intervalos discretos, poupando tempo e recursos computacionais (Figueredo, 2008).

Escolhendo apenas um conjunto de escalas e posições para fazer os cálculos, em que as escalas e as posições são escolhidas em potências de 2, a análise será muito mais eficiente. Esta análise é obtida através da transformada discreta de Wavelet (DWT – Discret Wavelet Transform). Um método eficiente para aplicar este esquema usando filtros foi desenvolvido por Mallat, 1988. O algoritmo de Mallat é um esquema clássico conhecido para processamento de sinal como codificador de sub banda de dois canais. Este prático algoritmo dá origem à transformada rápida de Wavelet – uma caixa na qual o sinal passa, e na saída são obtidos os coeficientes de Wavelet (Mendes, 2005).

3.4.1. Coeficiente de aproximação e detalhe

Para muitos sinais, o conteúdo a baixa-frequência é a parte mais importante. E isso dá ao sinal a identidade. O conteúdo de alta-frequência, por outro lado, dá a característica ou a diferença. Na análise de Wavelet, fala-se de aproximações e detalhes. As aproximações são os componentes de baixa-frequência e escala-alta do sinal. Os detalhes são os componentes de alta-frequência e escala-baixa do sinal. (Mendes, 2005)

A transformada discreta de wavelet faz uma decomposição do sinal baseada na divisão da frequência deste, usando um banco de filtros digitais, o filtro passa-alto (High pass) e o filtro passa-baixo (Low pass), exemplificados na Figura 3.3. Essas respostas apresentam metade da banda do sinal original (Figueredo, 2008).




Figura 3.3: Decomposição de um sinal nível 1. Fonte: Misiti, 2001

O processo de decomposição pode ser iterado, com sucessivas aproximações a serem decompostas, de forma a que um sinal seja dividido em muitas componentes de baixa resolução. Isto é chamado de “árvore de decomposição de Wavelet” (Figura 3.4) (Mendes, 2005).




Figura 3.4: Árvore de decomposição de um sinal com vários níveis. Fonte: Misiti, 2001

Na decomposição multinível wavelet, apenas os coeficientes de aproximação são novamente decompostos em coeficientes de aproximação e detalhes. Estes componentes podem ser conjugados no sinal original sem perda de informação, em comparação ao sinal original. Este processo é chamado reconstrução. Para sintetizar um sinal, este é reconstruído a partir do somatório das aproximações e dos detalhes obtidos na decomposição da wavelet (Figura 3.5).

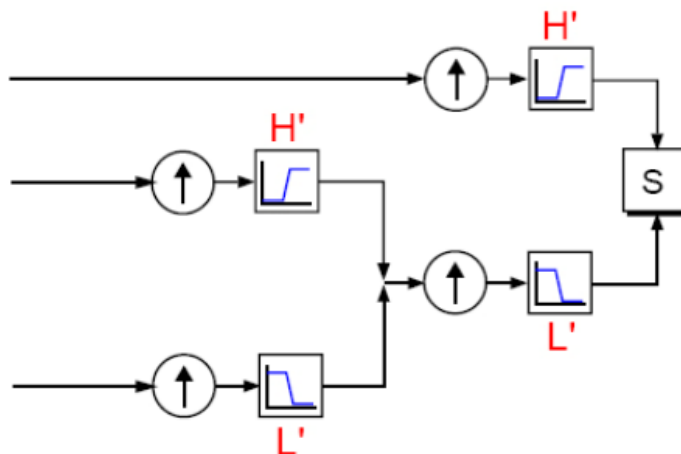


Figura 3.5: Reconstrução do sinal a partir dos coeficientes da Wavelet. Fonte: Misiti, 2001

3.5. Wavelet-mãe.

Há vários tipos de wavelets citados na literatura. O uso de cada um deles está associado a aplicação. As wavelets mãe (mother wavelet) são definidas por várias formas, pelas suas características no domínio de frequência ou então por uma equação específica no domínio do tempo (Figueredo, 2008).

3.5.1. wavelet de Haar

Haar descreveu uma base ortonormal de wavelets definida sobre o domínio $[0,1]$, ou seja, $h_0(x)$, $h_1(x)$, ..., $h_n(x)$, ... outras bases, além das de Fourier, tal que para qualquer função contínua $f(x)$ sobre o intervalo $[0,1]$ (Rocha, 2008).

Existem limitações no uso da construção de Haar. Como as funções base de Haar são funções de passos descontínuos, não são muito adequadas para a análise de funções estáveis com derivações contínuas (Wang, 2000).




Figura 3.6: Função wavelet Haar. Fonte: Haar, 1910.

A função base é conhecida pela sua simplicidade (Figura 3.6), pois analisa um sinal constante por partes, o que muitas vezes pode se tornar mais adequado.

3.5.2. Wavelet Chapéu Mexicano (Mexican Hat)

Essa wavelet tem sido muito utilizada na caracterização morfológica de superfícies e sinais biomédicos (Figura 3.7). Às vezes designada de Marr, ela é a segunda derivada da função de densidade de probabilidade gaussiana (Sheng, 1996). Ela é muito utilizada em estudos onde a localização temporal é importante e pode-se abrir mão da localização da frequência.




Figura 3.7: Função wavelet chapéu mexicano. Fonte: Misiti, 2001.

3.5.3. Wavelets de Daubechies

Um dos maiores desafios da teoria de wavelets foi a construção de uma família de wavelets ortogonais de suporte compacto. As wavelets ortogonais de Daubechies, “dbN”, são perfeitamente compactas no tempo, mas no domínio da frequência, tem um alto grau de superposição espectral entre as escalas. Exemplificada na Figura 3.8, sua maior vantagem é serem ortogonais, o que significa que um erro no sinal de entrada não cresce

com a transformação e a estabilidade numérica computacional é assegurada. Por outro lado, não possuem fase linear (Oliveira, 2007).




Figura 3.8: Funções wavelet Daubechies. Fonte: Misiti, 2001

3.5.4. Wavelet Symmlets e Wavelet Coiflets

Coiflets e Symmlets são wavelets mais simétricas as quais foram projetadas para garantir momentos nulos, tanto na função de escala $\varphi(t)$ quanto na wavelet-mãe $\psi(t)$. Elas foram criadas por Daubechies sob demanda de R. Coifman, com propriedades semelhantes a família “db”(Figura 3.9). São também wavelets de suporte compacto (Oliveira, 2007).




Figura 3.9: Funções wavelets Coiflets e Symmlets. Fonte: Misiti, 2001

4. Redes Neurais Artificiais

As redes neurais artificiais (RNA) surgiram a partir do interesse de pesquisadores no funcionamento do cérebro humano, o sistema mais flexível até hoje conhecido para processamento de informação.. Dada a força das RNAs em tarefas que envolvam reconhecimento de padrões, as aplicações clínicas das RNAs estão em fase de grande avanço. As RNAs são usadas em pesquisas para diagnóstico de demências, infarto do miocárdio, desordens psiquiátricas, embolismo pulmonar agudo, dentre outras (Wei, 1998).

4.1. Aprendizagem de máquinas

O mundo está repleto de dados, fotos, músicas, textos, vídeos, armazenados nos celulares, computadores ou até mesmo em plataformas na nuvem. Aprendizagem de máquinas (*Machine Learning*) tem como promessa dar sentido a todas essas informações (Barth, 2017). Esta técnica é uma aplicação da inteligência artificial (IA) que fornece aos sistemas a capacidade de aprender e melhorar automaticamente a partir da experiência (dados), sem ser explicitamente programado.

As pesquisas e técnicas desenvolvidas no domínio da aprendizagem da máquina revelam a busca por aparelhos e programas capazes de aprender automaticamente em sua interação com o ambiente. Estas aprendizagens automáticas envolvem um maior grau de autonomia e um menor grau de intervenção humana. O objetivo, neste caso, é possibilitar o desenvolvimento de máquinas e programas capazes de automodificação e autoaperfeiçoamento. Diferentemente de uma programação explícita, em que o programador delinea a solução de um problema, para gerar aprendizado de máquina, o programador deve ensinar a máquina a encontrar as próprias soluções a partir de suas experiências. Por exemplo, no caso de uma aprendizagem complexa, a máquina deve realizar automaticamente, a extração, categorização e classificação de informações, mesmo diante de uma imensa quantidade de dados (Campos, 2018).

Grandes empresas da área da informática revelaram suas técnicas e programas de aprendizagem de máquina. A Google (programa Tensor Flow), a Microsoft (programa DMTK) e o Facebook (programa Torch) disponibilizam sites com seus programas de

aprendizado da máquina. O importante para essas empresas não está em manter segredos sobre as técnicas de aprendizagem que utilizam, mas sim sobre muitos dos dados que possuem (Campos, 2018).

4.2. O que é um rede Neural?

Uma Rede Neural Artificial (RNA) é de acordo com (Wei, 1998) um modelo não-linear, computacional e matemático, para processamento de informações, com arquiteturas inspiradas na organização neuronal. Elas fazem uma representação distribuída da informação na forma de conexões entre um grande número de elementos simples, ou neurônios artificiais.

Todos estes elementos realizam operacionalmente a mesma função, executar a soma ponderada de suas entradas e executar uma transformação (linear ou não-linear) sobre este valor (Lopes, 2005). A grande vantagem do uso das RNAs para a solução de problemas complexos provém de algumas propriedades e capacidades úteis descritas a seguir, de acordo com (Haykin, 2001):

- **Aprendizagem:** É o processo em que o conhecimento é adquirido pela rede a partir de seu ambiente.
- **Generalização:** É o fato de a rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (Aprendizagem).
- **Não-linearidade:** RNA composta de neurônios artificiais também não-lineares. Esta é uma característica importante, pois a maioria dos sistemas físicos responsáveis pela geração dos sinais de entrada para a rede neural são não-lineares;
- **Adaptabilidade:** Capacidade de adaptar seus pesos sinápticos perante modificações do meio ambiente, ou seja, uma RNA treinada para operar em um ambiente específico pode ser facilmente re-treinada para absorver pequenas alterações no ambiente;
- **Tolerância a Falhas:** O conhecimento é distribuído pela RNA, desta forma, uma parte das conexões da RNA pode estar inoperante, sem que haja mudanças significativas no desempenho da rede. Uma RNA exibe uma degradação suave de desempenho em vez de apresentar uma falha catastrófica.
- **Resposta a Evidências:** Em sua utilização como classificadora de padrões, uma

RNA pode fornecer, em sua saída, não somente a informação relativa a qual conjunto a entrada pertence, mas também uma informação sobre a confiança no resultado. Desta forma, pode se utilizar destas informações para rejeitar padrões ambíguos.

4.3. Modelo de um Neurônio Artificial.

Para uma RNA, um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural (Haykin, 2001). Com seu funcionamento, basicamente como elemento integradores, tem como função coletar sinais advindos de outros neurônios, ou mesmo sinais de entrada da rede, ponderar os dados através de pesos específicos e repassar estes dados para outros neurônios ou para a saída da rede (Lopes, 2005).

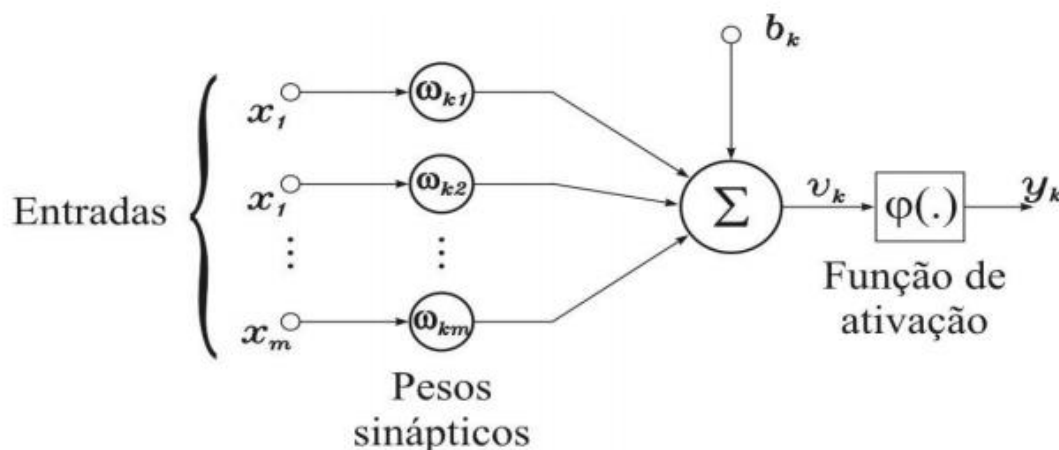


Figura 4.1: Modelo geral do neurônio artificial. Fonte: Haykin, 2001.

Com base na Figura 4.1 é possível distinguir alguns elementos considerados importantes na estrutura do neurônio:

- Sinapses: São caracterizadas por um peso w , que pode representar a sua intensidade. O papel do peso w_{kj} é multiplicar o sinal x_j na entrada da sinapse j , conectada a um neurônio k . O peso w_{kj} é positivo se a sinapse associada é excitatória e negativo se a sinapse associada é inibitória;
- Somatório: Adiciona as entradas ponderadas pelos seus respectivos pesos.

- Limiar (threshold, θ_k): Tem um papel determinante na saída do neurônio. Sua função é controlar a intensidade da função de ativação para se obter o desempenho desejado da rede. Se o valor de u_k for menor que este limiar, então, a saída do neurônio ficará inibida, em caso contrário, ficará ativa;
- Função de ativação: Funciona como um limitante à amplitude da saída do neurônio, ou seja, a entrada é normalizada dentro de um intervalo fechado, geralmente $[0, 1]$ ou $[-1, 1]$;
- Saída do neurônio: Representada por y_k ,

$$y_k = \varphi(u_k - \theta_k)$$

Eq. 6

onde φ é a função de ativação (Haykin, 2001; Lopes, 2005).

4.4. Tipos de funções de ativação

De acordo com (Haykin, 2001), existem três tipos básicos de função de ativação (Figura 4.2) utilizados em redes neurais que definem a saída de um neurônio em termos do campo local induzido v .

- I. Função de Limiar: Utilizada no neurônio de McCulloch–Pitts, em que a saída de um neurônio assume o valor 1 ou 0, descrevendo uma propriedade tudo-ou-nada do modelo, definida por:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases}$$

Eq. 7

- II. Função Linear por Partes: Essa função pode ser vista como uma aproximação de um amplificador não-linear, assumindo que o fator de amplificação dentro da região linear de operação é a unidade. É definida por:

$$\varphi(v) = \begin{cases} 1, & v \geq +\frac{1}{2} \\ v, & +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & v \leq -\frac{1}{2} \end{cases}$$

Eq. 8

III. **Função Sigmóide:** É a função mais utilizada e definida como uma função estritamente crescente que exhibe um balanceamento adequado entre comportamento linear e não-linear.

$$\varphi(v) = \frac{1}{1 + \exp(-\alpha v)}$$

Eq. 9

Onde α é o parâmetro de inclinação da função.

Algumas vezes é desejável que a função ativação se estenda de -1 a +1, ou seja, a função de ativação é uma função ímpar. Para o caso da função sigmoide, sua correspondente ímpar é a função tangente hiperbólica, definida por:

$$\varphi(v) = \tanh(v)$$

Eq. 10




Figura 4.2: Funções de ativação mais utilizadas. (a) Função Limiar. (b) Função Linear por partes. (c) Função Sigmóide com parâmetro de inclinação variável. Fonte: Haykin, 2001.

4.5. Topologias das redes neurais artificiais

É possível identificar três classes de topologias de rede fundamentalmente diferentes.

4.5.1. Redes não-recorrentes com camada única

As RNAs não-recorrentes não possuem realimentação de suas saídas para as entradas e por isso são ditas também “sem memória” (Figura 4.3). A camada única é a mais simples possível, em que uma camada de entrada de nós de fonte se projeta sobre uma camada de saída de neurônios (Haykin, 2001).




Figura 4.3: Rede não-recorrente com camada única. Fonte: Haykin, 2001.

4.5.2. Redes não-recorrentes com múltiplas camadas

Essa segunda classe se distingue pela presença de uma ou mais camadas ocultas (Figura 4.4).

- Neurônios ocultos: Tem como função intervir entre a camada externa e a saída rede, tornando a rede capaz de extrair estatísticas de ordem elevada. E é importante quando o tamanho da camada de entrada é grande (Haykin, 2001).

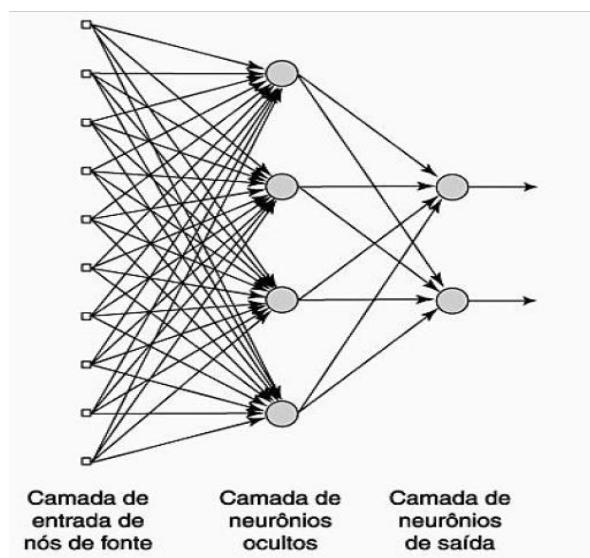


Figura 4.4: Rede não-recorrente multicamada com camada oculta. Fonte: Haykin, 2001.

4.5.3. Redes recorrentes

Uma rede neural recorrente se distingue por ter pelo menos um laço de realimentação. A presença desses laços tem um impacto profundo na capacidade de aprendizagem da rede e no seu desempenho (Haykin, 2001).

Suas estruturas não são obrigatoriamente organizadas em camadas. Quando são, estas redes podem possuir interligações entre neurônios da mesma camada e entre camadas não consecutivas, gerando interconexões bem mais complexas que as RNAs não-recorrentes. Nas RNAs recorrentes os neurônios têm conexões com eles mesmos e com outros neurônios, excitadores ou inibidores (Figura 4.5) (Lopes, 2005).




Figura 4.5: Rede recorrente com neurônios ocultos. Fonte: Haykin, 2001.

4.6. Tipos de treinamentos

Segundo Haykin (2001), o aprendizado no contexto das RNAs pode ser definido como o processo através do qual os parâmetros livres de uma RNA são adaptados através de um contínuo processo de estímulo pelo meio-ambiente. O tipo de aprendizado é determinado pela maneira através da qual a mudança dos parâmetros é efetivada e caracterizado, como na Figura 4.6.




Figura 4.6: Processo de aprendizado das Redes neurais

Uma das etapas da utilização de redes neurais é o treinamento, onde a rede “aprende” a partir de exemplos do domínio de aplicação. Essa aprendizagem pode ser supervisionada (onde os exemplos já possuem soluções) ou não-supervisionada (Figueredo, 2008). A aprendizagem supervisionada é normalmente utilizada em problemas de classificação e o foco deste trabalho, enquanto a aprendizagem não-supervisionada é geralmente utilizada em problemas de agrupamento.

4.6.1. Aprendizagem Supervisionada

O treinamento supervisionado necessita de um par de vetores composto do vetor de entrada e do vetor alvo que se deseja como saída. Juntos, estes vetores são chamados de par de treinamento (Haykin, 2001).

O procedimento de treinamento funciona da seguinte maneira:

- I. O vetor de entrada é aplicado.
- II. A saída da rede é calculada e comparada com o correspondente vetor alvo.
- III. O erro encontrado é então realimentado através da rede e os pesos são atualizados de acordo com um algoritmo determinado a fim de minimizar este erro.
- IV. Este processo de treinamento é repetido até que se obtenha níveis baixos de erro.

4.6.2. Aprendizagem Não-supervisionada

O treinamento não-supervisionado, não necessita de um vetor alvo para as saídas e, obviamente, não faz comparações para determinar a resposta ideal. O conjunto de

treinamento modifica os pesos da rede de forma a produzir saídas que sejam consistentes, isto é, tanto a apresentação de um dos vetores de treinamento, como a apresentação de um vetor que é suficientemente similar, irão produzir o mesmo padrão de saídas (Haykin, 2001).

4.7. Redes Multilayer Perceptron

O “perceptron”, a arquitetura mais simples de uma RNA, permite uma compreensão clara de como funciona uma rede neural em termos matemáticos. Um modelo que pode receber várias entradas e produz uma única saída binária. Um dispositivo que toma decisões ao comprovar evidências (Data Science Academy, 2019).

O “perceptron” de camada única só é capaz de classificar padrões linearmente separáveis. Quando o problema a ser trabalhado envolve um alto grau de não-linearidade, faz-se necessário o uso de um “perceptron” multicamadas. Seu treinamento é do tipo supervisionado e utiliza um algoritmo muito popular chamado “error backpropagation” (retro-propagação do erro).

4.7.1. Backpropagation

Este algoritmo é baseado numa regra de aprendizagem que “corrige” o erro durante o treinamento (Haykin, 2001). É um algoritmo de gradiente descendente, em que os pesos das sinapses se movem na direção do gradiente negativo da função performance. Quando treinada adequadamente, a rede tende a dar respostas razoáveis perante situações de entradas nunca vistas. Tipicamente, uma nova entrada tende a ter uma resposta similar à resposta adequada de uma entrada similar da usada no treino.

4.7.1.1. Funções de treino

As funções de treinos podem ser divididas de acordo com as técnicas utilizadas. Com o auxílio da Toolbox de Redes Neurais do Matlab, algumas dessas técnicas podem ser exemplificadas. As técnicas Heurística, que se baseiam na análise da performance dos algoritmos do gradiente descendente e descritas a seguir:

- Resilient backpropagation (trainrp): É a mais para reconhecimento de padrões, porém possui um menor desempenho quando o erro é muito baixo. Baixos requisitos de memória.
- Gradiente Descendente (traingd): Os pesos são ajustados na direção do gradiente negativo da função performance, em lote.
- Gradiente Descendente com momento (traingdm): O momento permite que a rede responda não apenas ao gradiente local, mas também aos valores recentes da superfície do erro. Isto dá a capacidade à rede de procurar além dos mínimos locais.
- Gradiente Descendente adaptativo (traingda): A traingda pode treinar qualquer rede desde que suas funções de peso, entrada líquida e transferência possuam funções derivadas. A retropropagação é usada para calcular derivadas do desempenho em relação às variáveis de peso e viés.

As técnicas de otimização, em especial ao algoritmo de Levenberg-Marquardt (trainlm) é uma função de treinamento de rede neural que atualiza os valores de peso e viés de acordo com a otimização de Levenberg-Marquardt . O trainlm é geralmente o algoritmo de retropropagação altamente recomendado como um algoritmo supervisionado de primeira escolha, embora exija mais memória que outros algoritmos.

4.7.2. A arquitetura de rede

Geralmente, esta arquitetura consiste em um conjunto de unidades sensoriais que formam uma camada de entrada, uma ou mais camadas intermediárias (ou escondidas) de unidades computacionais e uma camada de saída. Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para a saída.

- Camada de entrada: A camada de entrada é utilizada para receber os dados de entrada da rede. Esta camada, portanto, não realiza qualquer tipo de processamento, servindo apenas para receber e armazenar o vetor de entrada, ou seja, o padrão a ser classificado. O número de neurônios desta camada pode ser obtido facilmente pelo número de componentes do vetor de entrada do sistema.

- Camada de saída: A camada de saída tem o papel de coletar e armazenar as respostas da rede ao padrão inserido na entrada. Possui também uma estruturação relativamente simples, sendo composta de tantos neurônios quantas forem as classes do problema.

Entre a camada de entrada e a de saída, podemos ter uma ou mais camadas ocultas, assim denominadas por não possuir qualquer comunicação direta com os dados trabalhados. A principal função destas camadas é a de propiciar complexidade e não-linearidade para a rede.

5. Materiais e Métodos

5.1. Banco de dados

Os sinais de ECG utilizados neste trabalho foram obtidos a partir de um conjunto de base de dados denominado PhysioBank. O PhysioBank é um repositório que contém diversos sinais fisiológicos digitalizados e dados utilizados em pesquisas por parte da comunidade científica (Goldberger, 2000).

Para realização desse projeto, o arquivo escolhido para as amostras de sinal selecionadas foi o MIT-BIH Arrhythmia Database. O banco de dados de arritmia do MIT-BIH contém 48 trechos de meia hora de registros ambulatoriais de ECG de dois canais, obtidos de 47 indivíduos estudados pelo Laboratório de Arritmia da BIH entre 1975 e 1979. Na maioria dos registros, há a presença de dois sinais, sendo um o condutor de membro II modificado (MLII), obtido de eletrodos colocados no peito. O outro sinal, que não foi utilizado nesse trabalho, é geralmente uma derivação modificada V1 (ocasionalmente V2 ou V5 e, em um caso, V4); em que os eletrodos também são colocados no peito. As gravações foram digitalizadas em 360 amostras por segundo por canal, com resolução de 11 bits em uma faixa de 10 mV (Moody, 2001).

5.2. Pré-processamento

Por serem adquiridas na superfície do corpo, as características de um sinal de ECG têm traços de sinais elétricos de várias atividades de diferentes partes do corpo. As principais questões no processamento de bio-sinais, como o ECG, são reduzir o ruído, o isolamento e a identificação dos sinais de diferentes fontes (Vaseghi, 2006). A análise de ECG com o objetivo de detectar patologias clínicas deve ser o mais precisa possível (Mehta, 2016).

Nesse contexto, o objetivo desta seção é executar técnicas de pré-processamento para reduzir o ruído do ECG e seu ajuste para uma melhor identificação dos parâmetros. De acordo com a pesquisa na literatura disponível, foram selecionados alguns métodos

de pré-processamento de sinal de ECG. Esses métodos foram implementados e seus resultados comparados ao sinal bruto obtido por um banco de dados de registros disponíveis online apresentado na seção 5.1.

5.2.1. O sinal

Um sinal do banco de dados foi escolhido (sel103m.mat) e os métodos de pré-processamento, como cancelamento da componente DC, remoção da linha de base e utilização de filtros para remoção de ruídos, foram implementados. A partir do sinal bruto, uma amostra dos primeiros 60 segundos foi retirada, como mostra a Figura 5.1.




Figura 5.1: Sinal original “sel103m.mat” da base de dados MIT-BIH.

Para uma melhor visualização dos resultados e a possibilidade de análise do sinal no domínio da frequência, foi realizada a Fast Fourier Transform (FFT). A Figura 5.2 mostra o nível de ruído presente no sinal, onde é possível verificar um componente DC inicial e o ruído característico em 60 Hz.

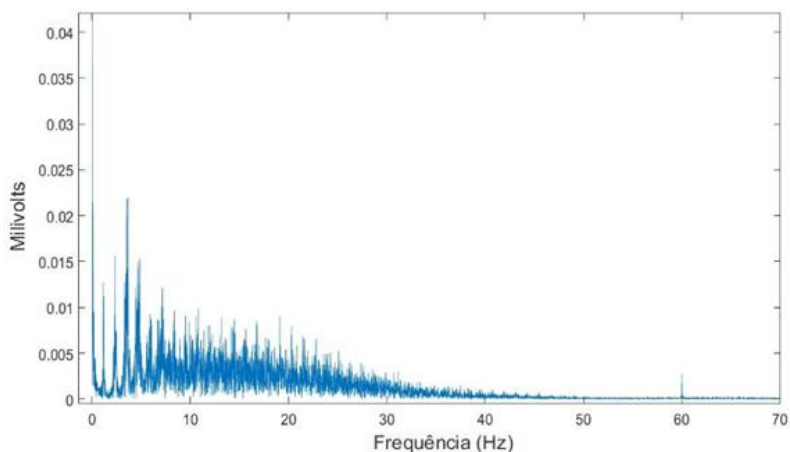


Figura 5.2: Sinal original após FFT.

Na Figura 5.3, os dois primeiros ciclos do sinal original foram selecionados como uma maneira de dar uma maior visibilidade aos detalhes do ruído e à percepção de um sinal não suavizado.




Figura 5.3: Seção dos dois primeiros ciclos cardíacos do sinal original.

Como observado na seção 2.4.1. o sinal de eletrocardiograma possui ruídos e interferências ocasionados por diversos fatores. Estas interferências podem ser reduzidas com a utilização de alguns métodos mencionados a seguir

5.2.2. Cancelamento da componente DC

O cancelamento da componente DC consiste em subtrair ao sinal ECG original, $y[n]$, o seu valor médio, ou seja, executando:

$$Y[n] = y[n] - \left(\frac{1}{N}\right) \sum_{n=1}^N y[n]$$

Eq. 11

Em que $Y[n]$ representa o sinal de ECG resultante, composto por n valores ($n=1, \dots, N$).

5.2.3. Remoção da Linha de base

A remoção da linha de base consiste na eliminação da componente de baixa frequência que causa a oscilação do valor médio das ondas do sinal de ECG.

Esta remoção pode ser efetuada subtraindo ao sinal original $y[n]$ o sinal $YY[n]$, resultando no sinal $YL[n]$:

$$YL[n]=y[n]-YY[n]$$

Eq. 12

Onde n é o tempo atual, $y[n]$ o sinal original e $YY[n]$ representa um sinal que pode ser obtido através da aplicação de técnicas como o filtro de médias móveis, função smooth do Matlab, etc.

5.2.4. Remoção do Ruído

Em um processo de identificação dos parâmetros encontrados no ECG, a remoção do ruído existente no sinal obtido é primordial. Se o sinal de ECG em estudo possuir um elevado nível de ruído, essa tarefa de identificação se torna ainda mais complicada. Assim sendo, consideraram-se e apresentam-se as seguintes técnicas de filtragem encontradas na literatura que eliminam o ruído existente, sem que a informação crucial do sinal ECG seja removida:

- Filtro média móvel:

O filtro de média móvel consiste na média de um conjunto de $(N+1)$ valores anteriores do sinal entrada $y[n]$, de modo a obter cada ponto do sinal de saída $YY[n]$. O filtro de média móvel é representado por:

$$YY[n] = \frac{1}{N+1} \sum_{k=0}^N y[n-k]$$

Eq. 13

Onde n representa o tempo atual, $N+1$ é o número de amostras utilizadas para a filtragem, $YY[n]$ representa o sinal filtrado e $y[n-k]$ representa o conjunto dos valores passados cuja média se vai calculando. Apesar de sua simplicidade, o filtro de média móvel é ideal para uma tarefa comum: reduzir o ruído aleatório, mantendo uma resposta ao passo (Yang, 2009).

- Função smooth

A função smooth (y) suaviza os dados no vetor de coluna y usando um filtro de média móvel. Os resultados são retornados em um vetor. O período padrão para a média móvel é 5. É utilizada para reduzir os ruídos de alta frequência e garantir uma linearidade ao sinal (Toolbox, 2001).

Os primeiros elementos são dados por:

$$\begin{aligned} aa(1) &= y(1) \\ aa(2) &= (y(1) + y(2) + y(3)) / 3 \\ aa(3) &= (y(1) + y(2) + y(3) + y(4) + y(5)) / 5 \\ aa(4) &= (y(2) + y(3) + y(4) + y(5) + y(6)) / 5 \end{aligned}$$

Eq. 14

- Função Detrend

A função Detrend remove o valor médio ou tendência linear de um vetor ou matriz, geralmente para processamento FFT. Utilizada no ECG para ajuste da linha de

base, o filtro calcula o ajuste de mínimos quadrados de uma linha reta (ou linha composta para tendências lineares por partes) nos dados e subtrai a função resultante dos dados (Teixeira, 2011; Yang, 2009).

$y = \text{detrende}(x)$ remove o melhor ajuste em linha reta do vetor x e retorna em y . Se x é uma matriz, detrend remove a tendência de cada coluna (Toolbox, 2001).

- Filtro FIR

Os filtros FIR (Finite Impulse Response) são filtros cuja resposta impulsiva tem um número finito de coeficientes não nulos. Utilizados para remoção de ruídos no ECG, estes filtros não apresentam realimentação e cada amostra da saída é uma média ponderada de amostras do sinal de entrada. O filtro FIR não recursivo pode ser representado como (Oppenheim, 2010):

$$y[k] = a_k x[k] + a_{-1k} x[k-1] + a_{k-2} x[k-2] + a_{k-3} x[k-3] + \dots$$

Eq. 15

- Filtro Butterworth

É um filtro com respostas suaves em todas as frequências com resposta plana nas bandas de corte e de passagem. No ECG, possui uma banda passante característica ao sinal, com frequência de corte entre 0,25Hz e 50Hz. O único filtro que mantém o mesmo formato para ordens mais elevadas, porém com uma inclinação mais íngreme na transição entre a banda passante e a de rejeição. O modelo típico é o filtro passa-baixo, que pode ser modificado para se tornar um passa-alto, ou colocado em série com outros filtros para formar filtros passa-banda, e versões de ordem mais elevadas destes.

5.2.5. Decomposição e Recomposição Wavelet

Como visto no capítulo 3, a transformada de wavelet faz uma decomposição do sinal, usando um banco de filtro digitais. Tendo como base o método de Magalhães (2012) (explicado nas próximas seções), podemos realizar a decomposição do sinal, utilizando a

função *wavedec* e a recomposição deste sinal utilizando a função *appcoef* ao nível, ou níveis.

Assim, com a utilização do coeficiente de aproximação, podemos fazer uma análise de resposta compatível com o filtro passa-baixa (Low-pass) e aplicado ao sinal de ECG como forma de redução dos ruídos característico. A função do Matlab utilizada pode ser descrita abaixo:

- $[C, L] = \text{wavedec}(X, N, \text{'wname'})$ retorna a decomposição wavelet do sinal X no nível N , usando 'wname' , como função a wavelet mãe. N deve ser um número inteiro estritamente positivo. A estrutura de decomposição de saída contém o vetor de decomposição wavelet C e o vetor de contabilidade L . 'wname' é uma string que contém o nome da wavelet.
- $A = \text{appcoef}(C, L, \text{'wname'}, N)$ calcula os coeficientes de aproximação no nível N usando a estrutura de decomposição da wavelet $[C, L]$

5.3. Identificação dos parâmetros

Os métodos apresentados a seguir serviram de referência para a elaboração do objetivo principal desse trabalho, a elaboração de um algoritmo que proporcionasse a identificação dos parâmetros do ECG de forma confiável e adaptável. O pré-processamento dos métodos analisados têm o objetivo de eliminar as interferências do sinal e proporcionar uma boa identificação dos picos, a base para a identificação dos parâmetros. Através de algoritmos de limiares, os máximos e mínimos são encontrados e classificados.

5.3.1. Método Lopes

O primeiro estágio do método é o tratamento do sinal cru e seu respectivo pré-processamento. A primeira etapa é o uso de um filtro de média móvel, que visa reduzir o ruído aleatório, mantendo uma resposta ao passo. O filtro de média móvel calcula o valor médio de um conjunto de amostras dentro de uma janela predeterminada. À medida que a janela se move sobre os dados, é calculada a média das amostras "visualizadas" dentro da janela. Para este trabalho, foi utilizado o comprimento da janela $N = 11$ (Teixeira, 2011). O próximo passo é o uso do filtro detrend, que remove uma tendência linear do sinal.

Após o processo de filtragem e correções, na identificação do ciclo cardíaco, esse método utiliza o coeficiente de correlação, ou seja, um vetor que contém o evento desejado que serve de comparação com os vários segmentos do mesmo comprimento de sinal, para registrar valores nos quais existam o complexo QRS e compara-lo com o resto do sinal. O objetivo é identificar os picos e conseqüentemente a presença do complexo QRS.

Após essa etapa é realizada a busca por valores máximos e seu índice, como a detecção do ponto R. O procedimento de correlação também foi utilizado para identificar os outros parâmetros, com o raciocínio de busca por picos e vales locais (Teixeira, 2011).

5.3.2. Método Pan-Tompkins

Para a implementação do método, os filtros passa-baixo e passa-alto foram colocados em cascata para obter uma faixa de passagem razoavelmente próxima do objetivo do projeto. O sinal após o carregamento é filtrado de acordo com a função de transferência descrita no método.

Foi utilizado um filtro passa-baixo Butterworth de segunda ordem com uma frequência de corte de cerca de 11 Hz e um ganho de 36. O atraso do processamento do filtro é de 6 amostras. Depois que o sinal passa pelo filtro passa-baixo, passa pelo filtro passa-alto, usando a função de transferência proposta. Foi utilizado um filtro Butterworth passa-alto de terceira ordem com uma baixa frequência de corte de aproximadamente 5 Hz e um ganho de 32. O atraso do processamento do filtro é de 16 amostras (Pan-Tompkins, 1985).

Após a filtragem são observados os seguintes passos:

- Derivação: O procedimento derivativo suprime os componentes das ondas P e T de baixa frequência, e fornece um grande ganho para os componentes de alta frequência decorrentes das altas encostas do complexo QRS.
- Quadrado: O cálculo do quadrado faz com que o resultado da saída seja positivo e enfatiza grandes diferenças resultantes do complexo QRS. As pequenas

diferenças decorrentes de ondas P e T são suprimidas. Os componentes de alta frequência no sinal relacionados com o complexo QRS são reforçados.

- **Integração:** A saída do operador derivativo base tem vários picos com uma duração de um único complexo QRS. O algoritmo de Pan-Tompkins executa uma suavização da presente saída da operação através da aplicação de um filtro de integração a uma janela de movimento. Se a janela for muito larga, a forma de onda de integração irá misturar o complexo QRS e onda T. E se a janela for estreita poderá agregar vários picos num único QRS.
- **Thresholding:** O procedimento de *thresholding* (*Ajuste de limiar*) no algoritmo Pan-Tompkins adapta-se às mudanças no sinal de ECG calculando estimativas de funcionamento do sinal e dos picos de ruído. Um pico é detectado sempre que a saída final mudar de direção dentro de um intervalo específico (J. Pan and W. Tompkins.1985; Bagarrão, 2014).

5.3.3. Método Magalhães

O primeiro passo deste método corresponde ao cancelamento da componente DC do sinal e depois a normalização, para que possua uma amplitude máxima de 1mV. Em seguida utiliza-se a função do Matlab *smooth* que retorna um sinal filtrado. Essa função suaviza os dados no vetor usando um filtro de média móvel em que o período padrão para a média móvel é 5. Depois remove-se a linha de base aplicando a subtração do sinal original ao sinal filtrado anteriormente (Magalhães, 2012).

Após o pré-processamento é realizada então a decomposição do sinal, utilizando a função *wavedec* e a recomposição deste sinal utilizando a função *appcoef* ao nível, ou níveis, que serão utilizados na análise. Esta etapa é importante, pois é através do sinal decomposto que será feita a procura dos pontos de máximo que representam a onda R.

A *wavelet* escolhida pelo autor para sinais de ECG foi a da família *Daubechies* definida como *Daub4* ou apenas *db4*, pois é a que mais se aproxima da forma do sinal em estudo. Realizada a decomposição do sinal, o próximo passo é a recomposição do sinal para cada um dos níveis desejados, neste caso do nível 4 ao nível 1. Este passo dá-se por intermédio da aplicação da Transformada Inversa *Wavelets* (IDWT), onde para cada um dos níveis desejados é necessário aplicar a IDWT recuperando assim o sinal decomposto

no passo anterior, com o objetivo de retornar ao tamanho original do sinal e classifica-lo corretamente.

Em seguida a primeira componente do complexo QRS a ser encontrada é a onda R por ser a onda mais característica de todas. O próximo passo é localizar as ondas Q e S, completando assim o complexo QRS. Para isto sabe-se que a principal característica destes picos é o fato de estarem localizados antes e depois da onda R, respetivamente, sendo caracterizadas por serem os pontos mínimos que antecedem e sucedem a onda R. As ondas Q são detectadas considerando como sendo os pontos mínimos de uma janela de amostras com um alcance atribuído, o mesmo sendo válido para a onda S, onde a janela possui um alcance de amostras de distância da onda R.

De forma análoga ao que foi realizado com as ondas Q e S, a pesquisa de localização das ondas P e T desenvolve-se, levando em consideração que as ondas P e T representam picos máximos de onda anteriores e posteriores às ondas Q e S, respetivamente. Sendo assim, na localização das ondas P considerou-se todos os picos máximos contidos numa janela de amostras situada antes da onda Q e com um alcance de amostras, enquanto para a onda T se localizaram os picos máximos com um alcance entre amostras contidas numa janela de situada depois da onda S (Magalhães, 2012; Bagarrão, 2014).

5.4. Classificação dos Sinais

Nesta próxima seção, serão apresentados métodos de classificação e reconhecimento de dados com o uso de Redes Neurais Artificiais. Uma etapa importante do projeto que visa facilitar a identificação de cardiopatias, apoiando as decisões dos médicos com os dados obtidos de um eletrocardiograma de 24 horas.

5.4.1. Redes Neurais

Em Teixeira (2009), a concepção e treino da rede neural artificial recorreu ao Matlab em conjunto com a toolbox de redes neurais deste software. Seu sistema de classificação de caracteres utilizou redes do tipo FeedForward (FF), pois proporcionam

uma saída calculada diretamente a partir da entrada, sem elementos de realimentação nem atrasos.

A rede criada possui duas camadas escondidas (intermediárias) e treinada com o algoritmo de backpropagation. A função de transferência para as três camadas da rede é a Tan-Sigmoid, que na sua camada de saída permite obter valores entre 0 e 1, que foram convenientes no trabalho proposto e também neste projeto.

De acordo com Perales (2011), a aplicação de uma RNA segue um fluxograma padrão para treinamento e teste, em que primeiramente são gerados pesos sinápticos iniciais aleatoriamente com sorteio de dados para que eles apareçam em uma ordem diferente em cada repetição. Após o sorteio, coloca-se um dado de treinamento na entrada da rede onde será calculada a saída e, em seguida, calcula-se o erro da rede.

Com base na proposta desenvolvida por esse projeto, foi observado com uma maior atenção um dos testes desenvolvidos por Perales (2011), que com o uso do algoritmo de backpropagation, proporcionou o desenvolvimento de um algoritmo que utiliza também um processo de reamostragem das amostras. Esse processo, clona aleatoriamente as amostras, fazendo com que atinja o número desejado e garanta um relativo peso no algoritmo.

Em Rocha (2010), o esquema de classificação de seu trabalho, que envolve redes neurais artificiais, utiliza duas redes do tipo feed-forward treinadas com as características obtidas previamente em sua etapa de extração de características. O algoritmo utilizado é o Levenberg-Marquardt. O número de camadas é o mesmo para cada derivação estudada, sendo duas camadas ocultas mais a de entrada e saída. A função de transferência é a tangente sigmoide. O número de neurônios na entrada corresponde ao número de características extraídas no processo, enquanto a saída contém apenas um neurônio, que fornece o resultado correspondente.

6. Aplicações e Resultados

A partir do conteúdo apresentado nas seções anteriores, esse capítulo tem o objetivo de demonstrar a aplicabilidade dos métodos analisados e posteriormente, a implementação de um método proposto baseado nos resultados obtidos. O processo de reconhecimento dos parâmetros de um sinal de ECG e sua respectiva classificação pode ser dividida em três etapas: Pré-processamento, Extração dos parâmetros do sinal e classificação. Que serão analisadas nas seções a seguir.

6.1. Pré-processamento

Como já discutida no capítulo anterior, o processo de pré-processamento é primordial para uma boa extração dos parâmetros. A detecção é difícil, não só pela fisiologia variável dos complexos, mas também por conta dos vários tipos de ruídos que podem estar presentes no sinal do ECG. Essas fontes de ruídos foram apresentadas na seção 2.4. e agora serão reduzidas ou excluídas do sinal, de acordo com os métodos propostos na literatura.

6.1.2. Implementação dos métodos

6.1.2.1. Método Vanda Lopes

Como visto na seção 5.1.1. o método propõe a utilização de um filtro de média móvel, com comprimento de janela $N=11$. O filtro é aplicado com o auxílio da função desenvolvida por (Teixeira, 2011). O próximo passo é o uso do filtro detrend com o uso da função do Matlab **detrende (x)**, onde o x é o sinal oriundo do filtro de média móvel. O resultado pode ser visualizado na Figura 6.1.




Figura 6.1: Seção dos dois primeiros ciclos cardíacos após o uso do método Lopes.

Para uma melhor visualização e interpretação dos efeitos causados pelo processo proposto pelo método, foi realizada a Transformada Rápida de Fourier (FFT) com a função `fft(x)` disponível no Matlab (Figura 6.2).




Figura 6.2: Sinal suavizado do método Lopes.

6.1.2.2. Método Pan-Thompkins

O método desenvolvido por J. Pan and W. Tompkins (1985) foi aplicado com a utilização de um filtro passa-baixo butterworth de baixa ordem, com uma frequência de corte de cerca de 11 Hz e um ganho de 36. Depois que o sinal passa pelo filtro passa-baixo, em forma de cascata, o sinal segue por um filtro passa-alto, utilizando a função de

transferência proposta. Foi utilizado um filtro butterworth passa-alto de terceira ordem com uma baixa frequência de corte de aproximadamente 5 Hz e um ganho de 32 (Pan-Tompkins, 1985).

Esse processo foi realizado com a função **butter** e a função filtragem digital **filtfilt**, ambas disponíveis no software Matlab e seu resultados visualizado na Figura 6.3 a seguir.




Figura 6.3: Seção dos dois primeiros ciclos cardíacos após o uso do método Pan-Thompkins.

Como no método anterior, também foi realizada um FFT para melhor visualização dos resultados (Figura 6.4).




Figura 6.4: Sinal suavizado do método Pan-Thompkins.

6.1.2.3. Método Willian Magalhães

O processo de pré-processamento desse método corresponde primeiro ao cancelamento da componente DC do sinal e depois a normalização, para que possua uma amplitude máxima de 1mV. Em seguida utiliza-se a função do Matlab *smooth*, que devolve um sinal filtrado, visualizado na Figura 6.5.




Figura 6.5: Seção dos três primeiros ciclos cardíacos após o uso do método Magalhães.

Como observado na seção 5.2.4. a função **smooth** pode ser definida como um filtro de média móvel e seus resultados podem ser comparados a seção anterior (Figura 6.1).

O método Lopes apresentou uma boa taxa de redução de ruído, eliminando o ruído característico de 60Hz e suavizando o sinal original, como mostrado nas Figuras 6.1 e 6.2. No entanto, o método não eliminou o componente DC inicial e também não ajustou a linha de base do sinal, que é muito importante para a detecção precisa dos parâmetros usados.

De acordo com Smith (1997), o filtro de média móvel usado no método é um modo de suavização excepcionalmente bom (a ação no domínio do tempo), mas um filtro passa-baixa excepcionalmente ruim (a ação no domínio da frequência). No entanto,

analisando os padrões gerais de sinal, o filtro detrend remove, em parte, algumas tendências lineares, o que pode dificultar a análise dos dados. Assim, são necessários mais filtros para reduzir as fontes de ruído.

O resultado do pré-processamento do sinal original através dos filtros passa-baixa e passa-alto em cascata, como visto nas Figuras 6.3 e 6.4, é possível visualizar que o método foi capaz de reduzir o ruído, eliminando também o componente DC inicial e características de ruído a 60 Hz. De acordo com Blackledge (2016), os filtros apresentados processam o sinal para reduzir a interferência, permitindo o uso de limites de baixa resolução para obter alta sensibilidade de detecção no método.

O filtro passa-baixo atenuou os componentes de alta frequência e as baixas frequências obedeceram à faixa especificada. O filtro passa-alto operou de maneira oposta, atenuando os componentes de baixa frequência.

6.1.3. Decomposição e Recomposição Wavelet

A partir dos conceitos observados no capítulo 3 e no método Magalhães, é possível realizar uma análise compatível com o filtro passa-baixa, que responde de acordo com a utilização da wavelet-mãe aplicada. Assim, as próximas seções apresentam esse processo de escolha da melhor wavelet-mãe e seus respectivos resultados na utilização do coeficiente de aproximação nos diferentes níveis.

6.1.3.1. Escolha da wavelet-mãe.

A partir do sinal original, é possível analisar a recomposição do sinal com a utilização dos diferentes tipos de wavelets. Exemplificadas a seguir com o uso do Wavelet Toolbox do software MatLab e as funções `wavedec` (decomposição) e `appcoef` (recomposição):

- Wavelet Haar;




Figura 6.6: Coeficiente de aproximação com uso da wavelet Haar de (a)nível 1, (b) nível 2, (c) nível 3.

- Wavelet Daubechies;

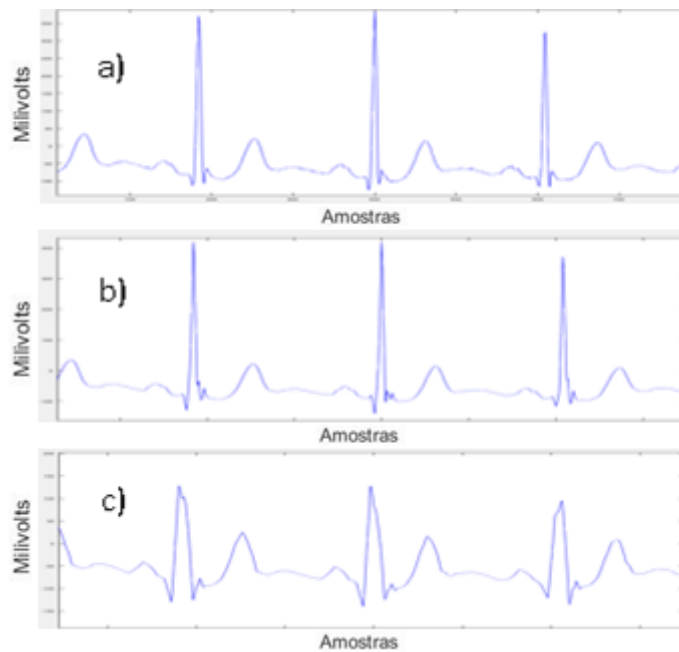


Figura 6.7: Coeficiente de aproximação com uso da wavelet Daubechies de (a)nível 1, (b) nível 2, (c) nível 3.

- Wavelet Symmlets;




Figura 6.8: Coeficiente de aproximação com uso da wavelet Symmlets de (a)nível 1, (b) nível 2, (c) nível 3.

- Coiflets.




Figura 6.9: Coeficiente de aproximação com uso da wavelet Coiflets de (a)nível 1, (b) nível 2, (c) nível 3.

A partir dos resultados obtidos na análise do uso das wavelets-mãe, é possível identificar um melhor padrão aos sinais biológicos do ECG a wavelet Daubechies de nível 2, ou seja, na recomposição do sinal, o nível que apresentava uma maior semelhança ao sinal original era o de nível 2. De acordo com Gomes (2008), a frequência desse tipo de filtro é melhor, pois há uma faixa mais larga de trabalho nos nulos espectrais, o que permite um melhor posicionamento da zona de interesse do sinal. Assim, em relação ao quesito de cancelamento de ruído, tema da seção deste trabalho, a wavelet de Daubechies (db4) apresenta um resultado muito bom. O que pode ser comprovado em Figueredo (2008), que também faz uso da mesma wavelet por considera-la mais recomendada para análise de sinais elétricos por se aproximar mais da forma do sinal original. Assim, o sinal é decomposto até o nível 4, gerando em cada um dos níveis um coeficiente de aproximação, que são os componentes de baixa frequência e escala do sinal. O sinal vai sendo comprimido (Figura 6.10) e deve ser analisado de acordo com a finalidade do uso. No caso desse projeto, o nível 2 é que possuía as melhores características.




Figura 6.10: Recomposição nas escalas 1, 2, 3 e 4.

6.1.3.2. Wavelet Daubechies

Após a escolha do tipo de wavelet que melhor se adapta ao tipo de sinal estudado, o sinal foi decomposto com a utilização da função **wavedec** e “db4”, que é a decomposição até o quarto nível. A Figura 6.11, demonstra o resultado obtido e seu respectivo fator de escala, ou seja, a sua compressão, como analisado anteriormente no capítulo 3 do presente trabalho.




Figura 6.11: Decomposição do sinal original de 4 níveis.

Após a decomposição, o sinal foi recomposto em diferentes escalas, com utilização da função **appcoef**. Assim, é proporcionada uma validação da utilização do nível 2 apresentada por Magalhães (2008) e também, uma forma de observar um possível resultado melhor.

6.1.4. Filtros FIR

Como forma de continuidade deste trabalho, a análise com a utilização de filtros do tipo FIR tem a proposta de realizar uma comparação entre os resultados obtidos na seção anterior com a implementação desse tipo de filtro. Assim, com o uso da função **fir1**, o filtro em análise foi aplicado com uma frequência de corte de 45 Hertz e ordem $N=50$.

Essa frequência de corte (F_c) foi determinada de acordo com os resultados encontrados em Magalhães (2012) na utilização da wavelet Daubechies e sua

recomposição de ordem 2. Assim, como o sinal possui uma frequência de amostragem de 360 Hz e de acordo com o teorema de Nyquist, em que é dito que a taxa de amostragem deve ser maior que o dobro da componente de maior frequência ao analisar no sinal medido. O correspondente a recomposição de nível 2 é uma frequência de 45 Hz. A comparação pode ser observada na Figura 6.12.




Figura 6.12: Comparação entre os tipos de filtragem do sinal original no processo de remoção do ruído.

No processo de decomposição e recomposição do sinal com o uso de wavelet, o sinal original, antes da realização do processo, passou pela função **smooth** com um resultado que melhor atenuou a flutuação na linha de base, eliminando também a interferência de rede e a componente DC. Seu resultado com melhor atenuação do ruído foi de escala 2 na recomposição e conseqüentemente o que foi utilizado em Magalhães (2012).

E como forma de comparação entre os resultados obtidos em Pan-Tompkins, com a utilização do filtro butterworth, e a decomposição wavelet, foi implementado um filtro FIR de ordem elevada. Esse filtro apresentou uma resposta muito satisfatória para o trabalho proposto, como pode ser visualizada na Figura 6.12, atenuando o ruído presente no sinal de forma a obter a filtragem necessária.

6.1.5. Método proposto

O método proposto a seguir (Figura 6.13), é resultado da análise dos resultados obtidos na seção anterior em conjunto com o que foi encontrado pela pesquisa na literatura.




Figura 6.13: Método proposto.

O método desenvolvido por esse trabalho no pré-processamento do sinal de ECG pode ser dividido nas seguintes etapas:

- I. Aquisição do Sinal: Os sinais utilizados nesse projeto foram obtidos a partir do banco de dados disponível online (PhysioBank). O arquivo com as devidas amostras foi o MIT-BIH Arrhythmia Database.
- II. Eliminação da componente DC: subtrair ao sinal ECG original, o seu valor médio.
- III. Eliminar a interferência de rede e atenuar a linha de base: A aplicação da função **smooth** e **detrend** em sequência.
- IV. Filtragem: Uso do filtro FIR a partir da função **fir1** aplicada com a função **filter** de forma sequencial, alternando apenas o tipo do filtro em “low” e “high” de acordo com os termos utilizados pelo Matlab.

A função **smooth** e **detrend** realizam bem as suas funções e podem ser exemplificadas na Figura 6.14. E o processo de filtragem pode ser observado na Figura 6.15, mantendo como base de análise o sinal 103m do banco de dados utilizado.




Figura 6.14: Comparação entre o sinal original e o sinal suavizado.




Figura 6.15: Comparação entre o sinal original e o filtrado.

A componente DC e a interferência de rede também são suavizadas com o método proposto, podendo ser melhor visualizada na Figura 6.16 com a transformada FFT.




Figura 6.16: Sinal 103m no domínio da frequência.

6.2. Extração de parâmetros do sinal de ECG

Como já mencionado anteriormente, o principal objetivo deste trabalho é a identificação dos eventos que ocorrem em um eletrocardiograma de forma automática. Para o processo de identificação de patologias através de um exame de eletrocardiograma são primordiais a extração de parâmetros e a correta identificação dos eventos do sinal de ECG, possibilitando uma análise clínica confiável do paciente. Após as etapas de pré-processamento, as interferências foram suavizadas e a identificação das curvas presentes no ECG podem agora ser identificadas.

6.2.1. Método utilizado

O método proposto nesse trabalho é oriundo das observações encontradas na literatura e com base nos métodos de Pan-Tompkins (1987) e Magalhães (2004).

6.2.2. Picos R

O primeiro passo para uma boa classificação dos eventos que ocorrem no sinal é uma excelente identificação de cada ciclo cardíaco, iniciando pela identificação da onda R. O ciclo cardíaco apresenta uma propagação das ondas de uma forma que não terão a mesma duração, ou seja, não é constante. Assim, é necessária a utilização de um sistema que faça essa identificação de forma adaptativa e com o menor erro possível. Para isso, foram seguidas as seguintes etapas no processo:

- I. Filtro Derivativo
- II. Quadrado
- III. Limiar Adaptativo

Após o pré-processamento aplicado anteriormente, o sinal filtrado é derivado como forma de suprimir os componentes das ondas P e T de baixa frequência. Com uma função de transferência (Equação 16), o sinal é filtrado com a utilização da função **filter**.

$$b = [1 \ 2 \ 0 \ -2 \ -1].*(1/8)*fs;$$

Eq. 16

Com o resultado obtido no processo, o sinal agora é elevado ao quadrado (Figura 6.17) como forma de evidenciar a presença dos picos mais visíveis, os picos R. Cada pico identificado representa um ciclo cardíaco.




Figura 6.17: Sinal 103m elevado ao quadrado.

O próximo passo é o procedimento de *Limiar* do algoritmo Pan-Tompkins, que adaptar-se às mudanças no sinal de ECG calculando estimativas de funcionamento do sinal e dos picos de ruído. Um pico é detectado sempre que a saída final mudar de direção dentro de um intervalo específico.

Nas equações abaixo (Equação 17-21), SPKI representa um pico geral que o algoritmo assumiu ser o correspondente aos picos QRS (Pico R) e o NPKI representa o

nível do pico relacionado a eventos não QRS (ruído, EMG, etc.). Os *THRESHOLD I1* e *I2* são dois limites utilizados para categorizar picos detectados como sinal (QRS) ou ruído. Mesmo os novos picos são categorizados como pico de sinal ou pico de ruído. Se o pico excede o *THRESHOLD I1* durante o primeiro passo da análise, é classificado como um pico do sinal (QRS). Se a técnica de procura (descrita no próximo ponto) for usada, o pico deverá estar acima do limite do *THRESHOLD I2* para ser chamado de QRS. Os níveis de pico e os limites são atualizados após cada pico e podem ser detectados e classificados através das seguintes equações:

$$SPKI=0.125 PEAKI+0.875 SPKI, \text{ se } PEAKI \text{ é um pico do sinal.} \quad \text{Eq. 17}$$

$$NPKI=0.125 PEAKI+0.875 NPKI, \text{ se } PEAKI \text{ é um pico de ruído.} \quad \text{Eq. 18}$$

$$THRESHOLD I1=NPKI+0.25(SPKI-NPKI); \quad \text{Eq. 19}$$

$$THRESHOLD I2=0.5THRESHOLD I1. \quad \text{Eq. 20}$$

Sempre que for detectado um QRS no procedimento de procura usando o *THRESHOLD I2* a fórmula atualizada para *SPKI* é:

$$SPKI=0.25 PEAKI+0.75 SPKI \quad \text{Eq. 21}$$

Após a implementação do algoritmo, é gerado uma matriz *rloc* com a localização de cada pico R encontrado no sinal e uma matriz *ramp* com a amplitude de cada um desses picos. O objetivo dessa identificação é posteriormente realizar a localização correta do pico R.

A partir dessa localização é possível também determinar a distância R-R, ou seja, a distância entre dois ciclos cardíacos. E esse valor é obtido a partir de uma função **for**, em que o valor *rloc+1* é subtraído de *rloc* até o final do sinal analisado. Com a posse desses valores, é possível elaborar uma tabela com gráficos dos sinais 100m, 112m e 116m da base de dados, comparando os resultados do nosso padrão ouro com os obtidos no algoritmo. As Figuras 6.18, 6.19 e 6.20, mostram a tendência de adaptabilidade do

algoritmo de Pan-Tompkins, gerando a opção de escolha pelo mesmo para esse trabalho. Essas figuras representam a diferença entre o valor indicado pelo banco de dados analisado e os valores encontrados com o método proposto, indicando que com o passar do tempo o algoritmo vai se adaptando, e essa diferença, ou erro entre os valores encontrados, tende a zero.




Figura 6.18: Erro de identificação com o passar do tempo (a) em 100m, com intervalo de 60 segundos (b).




Figura 6.19: Erro de identificação com o passar do tempo (a) em 112m, com intervalo de 60 segundos (b).




Figura 6.20: Erro de identificação com o passar do tempo (a) em 116m, com intervalo de 60 segundos (b).

Na Figura 6.20(a), é possível observar que há uma falha de identificação, um falso negativo que proporcionou um novo valor de limiar e aumento do erro. O algoritmo se adapta e tende a continuar sua tendência a zero novamente.

Como forma de comparação e medição da taxa de acerto do método utilizado, o algoritmo foi aplicado aos 48 sinais disponíveis no MIT-BIH com os seguintes parâmetros iniciais para os filtros aplicados informados na Tabela 1.

Tabela 1. Parâmetros usados no processo de filtragem.

Filtro	Freq. de corte (Hz)	Ordem
Passa-baixa	30	40
Passa-alta	0.25	6

Na Tabela 2 os resultados com a utilização dos parâmetros descritos anteriormente podem ser observados. A variável ‘Batidas’ determina os ciclos cardíacos identificados pelo banco de dados. Com a presença de dois médicos especialistas, esses dados representam nosso padrão-ouro (Moody, 2001), ou seja, valores verificados e fies a realidade. A outra variável ‘Batidas_P’, representa os ciclos identificados pelo algoritmo proposto por esse trabalho.

A falha de Detecção é resultado da soma entre os falsos positivos e Falsos negativos encontrados. Os falsos positivos são os valores que superam o número máximo de batidas. Falsos negativos são aqueles que não atingem o número de batidas, ou seja, o algoritmo não conseguiu identificar corretamente todas as batidas. Sua taxa pode ser encontrada a partir da Equação 22.

$$\text{Falha de Detecção (\%)} = \frac{\text{Falha de Detecção}(n^{\circ})}{\text{Batidas}(n^{\circ})} \cdot (100)$$

(Eq. 22)

Tabela 2. Resultados da implementação do método com a Falha de detecção.

Sinal	Batidas (n°)	Batidas_P (n°)	Falsos positivos	Falsos Negativos	Falha de Detecção (n°)	Falha de Detecção (%)
100	2273	2272	0	1	1	0,04
101	1865	1866	1	0	1	0,05
102	2187	2187	0	0	0	0,00
103	2084	2083	0	1	1	0,05
104	2229	2276	47	0	47	2,11
105	2572	2599	27	0	27	1,05
106	2027	2021	0	6	6	0,30
107	2137	2134	0	3	3	0,14
108	1774	1897	123	0	123	6,93
109	2532	2532	0	0	0	0,00
111	2124	2123	0	1	1	0,05
112	2539	2539	0	0	0	0,00
113	1795	1794	0	1	1	0,06
114	1879	927	0	952	952	50,67
115	1953	1953	0	0	0	0,00
116	2412	2392	0	20	20	0,83
117	1535	1535	0	0	0	0,00
118	2288	2278	0	10	10	0,44
119	1987	1987	0	0	0	0,00
121	1863	1861	0	2	2	0,11
122	2476	2476	0	0	0	0,00
123	1518	1515	0	3	3	0,20
124	1619	1578	0	41	41	2,53
200	2601	2437	0	164	164	6,31
201	2000	1984	0	16	16	0,80
202	2136	2120	0	16	16	0,75
203	2980	2823	0	157	157	5,27
205	2656	2617	0	39	39	1,47
207	2332	2289	0	43	43	1,84
208	2955	2941	0	14	14	0,47
209	3005	3005	0	0	0	0,00
210	2650	2521	0	129	129	4,87
212	2748	2747	0	1	1	0,04
213	3251	3241	0	10	10	0,31
214	2262	2250	0	12	12	0,53
215	3363	3358	0	5	5	0,15
217	2208	2204	0	4	4	0,18
219	2287	2154	0	133	133	5,82
220	2048	2048	0	0	0	0,00
221	2427	2416	0	11	11	0,45
222	2483	2482	0	1	1	0,04
223	2605	2551	0	54	54	2,07
228	2053	2014	0	39	39	1,90
230	2256	2255	0	1	1	0,04
231	1573	1571	0	2	2	0,13
232	1780	1785	5	0	5	0,28
233	3079	3072	0	7	7	0,23
234	2753	2752	0	1	1	0,04
Total	110159	108462	203	1900	2103	1,91

Na tabela anterior, é possível verificar também que o algoritmo proposto obteve uma falha na detecção de 1,91% dos picos R encontrados, o que gera uma Taxa de Acerto do método de 98,09%.

O algoritmo genérico proposto baseado em Pan-Tompkins (1987) alcançou uma alta Taxa de Acerto (98,09%). Esse valor foi superior às referências (Pachauri; Bhuyan, 2009)(96,65%); (Jaswal; Parmar; Kaul, 2012)(95,74%); (Nanavati, 2012)(82,2%) e (Magalhães, 2012)(95,91%); e inferior às referências (Pan; Tompkins, 1985)(99,3%); (Yeh; Wang, 2008)(99,75%); e (Haddadi, 2014)(98,1%).

6.2.3. Complexo QRS

Após encontrada a localização dos picos R e conseqüentemente dos valores que compreendem a distância R-R entre os ciclos cardíacos, a identificação dos picos Q e S completam assim o total conhecimento do complexo QRS. O método proposto por esse trabalho se baseia no método de Magalhães (2012). Esse método tem como ideia principal a localização dos mínimos pontos das amostras. Ou seja, de acordo com o limiar apresentado, é buscado um valor mínimo anterior e posterior ao pico R dentro de um determinado intervalo de amostras.

- Onda Q

A partir da posição rloc, é determinado um intervalo de -5 até -20 amostras em que é procurado, através da função **min**, o pico Q negativo.

- Onda S

De forma análoga a localização da onda Q mas com um intervalo de +1 até +25 amostras.

6.2.4. Picos P e T

A localização dos picos P e T também se baseiam na localização de pontos extremos, mas por serem pontos positivos é utilizada a função **max** com um intervalo de varredura também delimitado previamente. Para o pico P, com origem em 'rloc', os valores anteriores e posteriores são -70 e -15 amostras. Na localização do pico T, os

valores utilizados são +25 e +130 amostras. Com uma frequência de amostragem de 360, o tempo para esses picos podem ser apresentados na Tabela 3.

Tabela 3. Representação em segundos do limiar para identificação dos picos Q, S, P e T.

Pico	Intervalo	
	Anterior	Posterior
Q	-0,056	-0,014
S	0,003	0,069
P	-0,194	-0,042
T	0,069	0,361

6.3. Janelas Pop-up

Com a implementação do método de identificação dos outros picos e análise da tabela 2, é possível determinar que alguns sinais não apresentam uma boa resposta a um intervalo de varredura fixo (limiar). E também, que os valores estabelecidos para a frequência de corte (F_c) e amplitude no processo de filtragem também podiam sofrer alterações que provocassem uma melhoria na identificação das curvas desejadas. Com base nisso, foi elaborada uma pequena interface com o usuário que proporciona um ajuste para obtenção de um melhor resultado.

A partir da função **menu**, foi estabelecido dentro de um **while** o processo de filtragem e identificação das curvas P e T. Como as curvas Q e S são consideradas fáceis de identificar, não foi atribuído a esse fator os problemas na identificação do restante das curvas. A árvore de decisão pode ser observada na Figura 6.21 e a interface será melhor explicada nos tópicos a seguir.

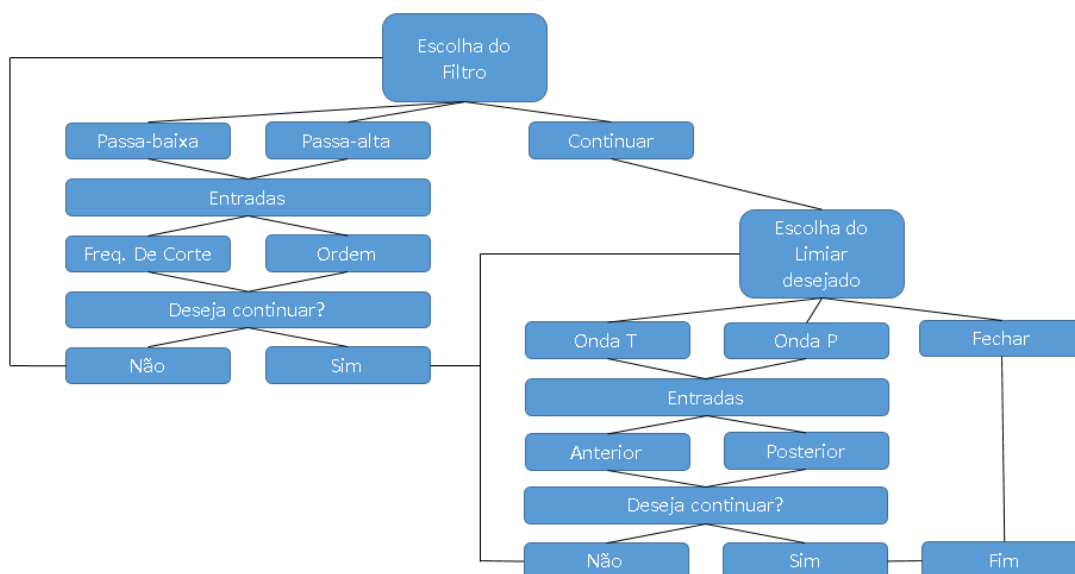


Figura 6.21: Esquemático da interface oferecida ao usuário para ajustes.

- Filtragem

Para uma melhor visualização dos ciclos, o sinal foi reduzido de 1 até 10000 amostras, o que geralmente compreende 3 ciclos cardíacos e um tempo de aproximadamente 2,78 segundos. Essa visualização do sinal vem acompanhada de um pop-up que pergunta se deseja realizar alguma alteração no sinal filtrado previamente, como visto na Figura 6.22.




Figura 6.22: Sinal 103m reduzido com presença da janela de decisão.

Caso o sinal esteja filtrado corretamente, o usuário deve clicar em “continuar” para o seguimento do programa e o processo de identificação das curvas. Em contrapartida, se clicar em “Lowpass” ou “Highpass”, o programa abrirá uma nova janela

para que seja introduzido os novos valores desejados. Com a confirmação do “OK”, o programa ira atualizar o gráfico com os novos valores a serem visualizados e abrirá uma nova janela de confirmação, perguntando ao usuário se deseja ou não continuar com o processo. Esses passos podem ser visualizados na Figura 6.23 a seguir.



Figura 6.23: Janelas de decisão para alterar os valores dos filtros.

- Onda P e T

Com o fim do processo de filtragem, o próximo passo é o ajuste do limiar utilizado para encontrar as ondas P e T. Como no estágio anterior, é fornecido ao usuário uma pré-visualização do sinal com as respectivas marcações de picos e uma janela com a possibilidade de alteração desse limiar, exemplificado na Figura 6.24.




Figura 6.24: Sinal 103m reduzido, com marcação dos picos e presença do pop-up de decisão.

E analogamente ao que acontece com o processo de filtragem, temos três opções de escolha, em que ao clicar em “fechar” o programa se encerra e a identificação dos picos ocorre em todo sinal. Ou, ao escolher “Onda P” ou “Onda T”, é aberta uma nova janela para que seja introduzido os novos valores desse limiar, caracterizado como

“anterior” e “posterior”, ou seja, o ponto anterior e posterior de limite da onda escolhida. Após a confirmação dos novos valores, será atualizado o gráfico com as marcações dos picos e será gerada uma nova janela para confirmar o seguimento ou não do processo, o que pode ser exemplificado com a Figura 6.25 abaixo.



Figura 6.25: Janelas de decisão para alterar os valores dos limiares.

6.3.1. Picos P e T

Após a etapa de ajuste oferecida ao usuário na seção anterior, é possível determinar com uma maior exatidão as curvas presentes no sinal. Para essa nova etapa, foram escolhidos os sinais que identificaram em 100% os picos R de acordo com a Tabela 2. Pois para uma identificação correta das ondas presentes no ECG, utilizando a estratégia de máximos e mínimos, um bom reconhecimento do pico R é primordial, ou seja, a partir do pico R é que serão definidos os limiares para identificação dos picos restantes.

Na Tabela 3 a seguir, são utilizados nove sinais do MIT-BIH com variação no processo de filtragem e de limiar das ondas. O processo de identificação das ondas foi baseado no ajuste empírico dos sinais com objetivo de um melhor acerto correspondente as ondas buscadas.

Tabela 4. Identificação das ondas P e T com ajuste de filtragem e limiar.

Sinal	LP		HP		Limiar(Threshold)				Identificação				
	Fc	Ordem	Fc	Ordem	Onda P		Onda T		P	Q	R	S	T
					Anterior	Anterior	Anterior	Posterior					
102	40	20	0.25	6	80	15	40	130	25	34	34	34	33
109	35	30	0.25	6	75	20	25	130	11	44	44	44	43
112	30	40	1	10	70	15	25	130	40	40	40	40	39
115	35	40	0.25	6	70	15	25	130	29	29	29	29	29
117	45	40	1	10	70	15	25	130	23	23	23	23	23
119	45	35	0.25	6	80	15	25	140	23	30	30	30	23
122	30	30	0.25	6	70	15	25	130	41	41	41	41	41
209	30	20	1	6	70	15	25	130	43	43	43	43	43
220	30	20	0.25	6	70	15	25	130	34	34	34	34	34

A Tabela 4 apresenta valores de identificação positivos, pois em virtude de os sinais analisados não serem totalmente saudáveis, como visualizado no anexo I, os picos foram, em sua maioria, identificados. Para obter um índice de comparação com os métodos presentes na literatura, foi determinada uma taxa de acerto do programa desenvolvido nesse trabalho com base no número total de pontos identificáveis e a falha de identificação desses. O resultado encontrado pode ser considerado satisfatório, que mediante as alterações propostas obteve uma taxa de acerto de 96,29%. Uma boa taxa, visto que a identificação das curvas P e T são as mais difíceis de realizar. O trabalho desenvolvido por Magalhães (2012), que realiza um processo similar, não obtém resultados satisfatórios nessa identificação, proporcionando apenas as taxas do complexo QRS, já apresentadas anteriormente.

Tabela 5. Taxa de acerto dos das curvas presentes no ECG.

Sinal	Total de pontos	Falha	Taxa de acerto (%)
102	170	10	94,12%
109	220	34	84,55%
112	200	1	99,50%
115	145	0	100,00%
117	115	0	100,00%
119	150	14	90,67%
122	205	0	100,00%
209	215	0	100,00%
220	170	0	100,00%
Taxa total	1590	59	96,29%

6.4. Classificação dos sinais

A partir dos dados obtidos nas seções anteriores, o próximo passo desse trabalho é o desenvolvimento de um sistema de classificação dos sinais obtidos online do banco de dados do MIT-B e processados pelo algoritmo proposto anteriormente. Para isso, os 48 sinais tiveram seus parâmetros identificados, ocorrendo na geração de dados que serviram de parâmetros de entrada para as redes artificiais propostas.

6.4.1. Parâmetros de entrada

Os sinais processados e devidamente identificados com seus parâmetros, geram dados relativos a cada um de seus picos, como a localização e sua amplitude em determinado ponto do sinal analisado. Para este trabalho, os parâmetros escolhidos foram:

- Distância R-R: A distância entre dois picos R, ou seja, a distância entre dois ciclos cardíacos.
- Duração do complexo QRS: O tempo entre a localização do pico Q até a localização do pico S, caracterizando a duração do complexo.
- Amplitude R: A amplitude do pico R, seu tamanho no sinal analisado.
- Distância S-T: A distância entre os picos S e o próximo pico T.
- Frequência: Com a localização de cada pico R, é possível determinar a frequência de cada batimento cardíaco.

De acordo com o Anexo I, o MIT-BIH Arrhythmia Database Directory (Records) é possível determinar a presença ou não de patologias no sinal indicado. Com isso, foi possível classificar, a partir dos dados fornecidos pela base de dados, na Tabela 6, um número total de arritmias presentes nos 48 sinais estudados.

Tabela 6. Arritmias encontradas nos 48 sinais do MIT-BIH.

Arritmias cardíacas	Total
Batida normal	40
Batida de bloco de ramo esquerdo	4
Batida de bloco de ramo direito	6
Batida prematura atrial	27
Batimento prematuro atrial aberrante	7
Batida prematura nodal (juncional)	5
Batida prematura supraventricular	1
Contração ventricular prematura	37
Fusão de batimento ventricular e normal	17
Onda de vibração ventricular	1
Batida de escape atrial	1
Batida de fuga nodal (juncional)	5
Batimento de escape ventricular	2
Ritmo estimulado	4
Fusão de batida ritmada e normal	3
Onda P não conduzida (APB bloqueado)	5
Batida inclassificável	6

Segundo a Tabela 6 e o Anexo I, trechos do sinal completo com duração de 60 segundos foram extraídos e classificados em 0 ou 1, em que o “0” é um sinal saudável e o “1” caracterizado como patológico. A classificação serviu como base para formação do ‘target’, ou seja, a supervisão atribuída a rede neural e seu respectivo processo de aprendizagem supervisionada.

6.4.2. Matriz de Entrada

O sinal analisado compreende os primeiros 60 segundos de captação, todos os parâmetros pertencentes a esse intervalo foram selecionados. Os sinais foram limitados a 40 entradas para cada parâmetro, por medida de parametrização. Ou seja, os primeiros 40 ciclos e seus respectivos picos P-QRS-T foram utilizados na análise.

Neste trabalho, foram determinadas as seguintes configurações para a matriz de entrada:

- Dados sequenciais: Os parâmetros escolhidos anteriormente são designados em uma única coluna, de acordo com o sinal analisado. Os dados não possuem nenhuma segmentação, ou seja, os dados são identificados e implementados a tabela, exemplificada na Figura 6.26. Assim, uma coluna da matriz de entrada com os dados sequências era composta por: 40 entradas de distância RR, frequência, amplitude, S-T e duração do QRS, totalizando 200 entradas

Matriz				
0,6	▪Distância entre os picos R (R-R).			
0,58055556				
0,58611111				
0,58333333				
0,60277778				
100	▪Frequência dos batimentos cardíacos (pico R).			
103,349282				
102,369668				
102,857143				
99,5391705				
1,60003717	▪Amplitude dos picos R.			
1,54804795				
1,42350547				
1,47027628				
1,4862318				
0,6	▪Distância entre as curvas S e T.			
0,57777778				
0,58888889				
0,58055556				
0,60555556				
0,05	▪Duração do complexo QRS.			
0,05				
0,04722222				
0,05				
0,04722222				

Figura 6.26: Exemplificação da Matriz de entrada.

- Dados segmentados: É análogo ao item anterior, porém os dados são implementados na coluna segmentados, ou seja, com um intervalo entre os ciclos, que para este trabalho fora de 5 ciclos cardíacos.

6.4.3. Divisão das matrizes

Foram elaboradas duas configurações (Tabela 7), cada uma delas contou com a matriz de treino, teste e validação, conforme requer a teoria de redes neurais. A primeira é formada por dados segmentados, que correspondem a uma matriz 200x48 (200 entradas e 48 sinais). A matriz obedece uma regra de divisão dos dados, com 70% para a matriz de treinos, 15% para teste e 15% para validação, gerando um valor de 34 dos indivíduos para o treino, 7 para o teste e 7 para a validação.

A segunda configuração é análoga a primeira, mas o diferencial é que não utilizou dados segmentados e sim dados sequencias. Com a divisão 70-15-15%, também obteve o mesmo número de indivíduos em cada parte.

Tabela 7. Representação do Tipo e Tamanho das configurações das matrizes

Configuração	Tipo	Tamanho
1	Segmentado	200x48
2	Sequencial	200x48

6.4.4. Tipologia, arquitetura e treino da RNA

A rede desenvolvida nesse trabalho é do tipo FeedForward (FF), porque os dados utilizados são provenientes de estáticas e não têm elementos de realimentação nem atrasos, sendo a saída calculada diretamente a partir da entrada. A rede foi treinada com o algoritmo de backpropagation, os pesos da rede se movem na direção do gradiente negativo da função performance. Além disso, a rede possui camadas escondidas (intermediárias), pois de acordo com Perales (2011), e também observado em (Teixeira, 2009), a rede com duas camadas ocultas de neurônios é a que apresenta um melhor resultado comparativo. Uma componente fundamental das redes neurais artificiais é a função de ativação para limitar a amplitude da saída do neurônio e introduzir uma componente de não linearidade no processo computacional.

Para este trabalho, a função de ativação escolhida foi a “tansig”, pois como definida por (Haykin, 2001) possui um balanceamento adequado entre comportamento linear e não-linear e uma boa resposta ao sistema proposto.

O desenvolvimento da RNA teve como orientação e ponto de partida, a utilização de um toolbox disponível no Matlab (Neural Network Toolbox) com a seguinte configuração:

```
net=newff(p,t,[n_1_ce n_2_ce],[tansig,tansig,tansig],fun_train);
net=train(net,p,t,[],[],val,teste);
```

Nessa toolbox a rede é criada com o uso da função newff, onde ‘p’ é a matriz de treino, ‘t’ a matriz ‘target’, n_1_ce e n_2_ce é o número de nós da primeira e segunda camada escondida. Após a criação da RNA, é gerada uma saída com a utilização da função **sim**, que retorna um número entre 0 e 1 correspondente a classificação do indivíduo em saudável (0) ou patológico (1).

Essa saída pode variar de acordo com inúmeros fatores, e esse trabalho implementou diversas funções de treino, observadas na literatura, com o objetivo de encontrar uma melhor resposta ('trainrp', 'traingd', 'traingdm', 'traingda' e 'trainlm'). Outra forma de variação, é a mudança no número de nós das camadas intermediária, que em um primeiro momento foi de 40 para a primeira camada e 20 para a segunda. Depois, esse número caiu para 20 e 10 respectivamente.

Uma forma de verificar a taxa de acerto da rede neural é o uso de uma matriz teste com dados que não participaram de seu treinamento, ou seja, apresentar um novo dado a rede criada e verificar sua classificação. Com uso da tabela 3, foram testados os sinais 102, 109, 112, 115, 119, 122, 209 e 220, utilizando as mesmas premissas da identificação das curvas, isto é, os sinais que obtiveram bons resultados e 100% de identificação dos picos R. Assim, os resultados podem ser caracterizados como mais plausíveis de serem reais. A disposição dos sinais e sua respectiva categoria é demonstrada na Tabela 8.

Tabela 8. Categoria de cada sinal na matriz teste.

Matriz teste	
102	Patológico
109	Patológico
112	Saudável
115	Saudável
117	Saudável
119	Patológico
122	Saudável
209	Saudável
220	Saudável

Com o conhecimento da categoria dos sinais, os resultados dos sinais testes podem ser analisados a seguir, observando a variação dos nós das camadas e também das funções de treinamento.

Tabela 9. Resultados da configuração 1, indicando em verde os diagnósticos corretos.

Função de Treino	Nº de nós das camadas		Sinais - Configuração 1								
			1º	2º	102	109	112	115	117	119	122
trainrp	40	20	0,34514	0,70914	0,11601	0,00027	0,0149	0,01174	0,38792	0,00611	0,00366
traingd			0,24058	0,24724	0,34023	0,13678	0,34555	0,04162	0,38066	0,19126	0,09795
traingdm			0,46305	0,34021	0,23573	0,20744	0,09562	0,81731	0,3236	0,19098	0,08357
traingda			0,33441	0,41194	0,31622	0,11698	0,20221	0,2536	0,44039	0,30219	0,20907
trainslm			0,23481	0,49297	0,19439	0,0083	0,00752	0,22786	0,43786	0,33879	0,01762
trainrp	20	10	0,93053	0,6614	0,53331	0,00512	0,05628	0,00432	0,77454	0,28333	0,0077
traingd			0,24636	0,26978	0,12515	0,02652	0,08808	0,2823	0,36286	0,1072	0,05919
traingdm			0,40907	0,30089	0,2174	0,37453	0,31276	0,37755	0,25607	0,23685	0,24662
traingda			0,45947	0,29257	0,38408	0,09939	0,21881	0,19362	0,3269	0,25897	0,17147
trainslm			0,03696	0,27555	0,04089	0,02234	0,00864	0,05484	0,25918	0,13769	0,0721

Tabela 10. Resultados da configuração 2, indicando em verde os diagnósticos corretos.

Função de Treino	Nº de nós das camadas		Sinais - Configuração 2								
			1º	2º	102	109	112	115	117	119	122
trainrp	40	20	0,44675	0,33859	0,44675	0,32153	0,01049	0,33333	0,34043	0,71643	0,53129
traingd			0,41251	0,5709	0,2608	0,31119	0,2323	0,62383	0,45585	0,90133	0,98345
traingdm			0,05466	0,2151	0,04043	0,073	0,1752	0,15095	0,12583	0,91858	0,96065
traingda			0,19348	0,30297	0,33014	0,29664	0,39713	0,22207	0,27906	0,60956	0,94073
trainslm			0,00718	0,50936	0,0714	0,16779	0,1406	0,22038	0,07291	0,86339	0,26285
trainrp	20	10	0,64003	0,64003	0,64003	0,64003	0,64003	0,64003	0,64003	0,96871	0,03784
traingd			0,19271	0,39281	0,14925	0,48767	0,79087	0,50061	0,42737	0,3279	0,91813
traingdm			0,08029	0,32937	0,07911	0,08964	0,06494	0,2112	0,16565	0,34854	0,32779
traingda			0,47522	0,31715	0,36481	0,19423	0,29464	0,31444	0,41321	0,88007	0,34425
trainslm			0,01161	0,0462	0,01421	0,13194	0,18562	0,13492	0,06822	0,07717	0,48667

Nas tabelas anteriores podemos visualizar os resultados respectivos a cada função de treinamento e número de nós aplicado. Com a aplicação de um limiar de 50%, ou seja, a utilização de um valor de referência para determinar se o trecho analisado é saudável (menor que 0,25), patológico (maior que 0,75) ou inconclusivo (todos os valores fora da margem aceitável, podemos classificar os dados. Os valores marcados com um fundo verde possuem um diagnóstico correto de acordo com o limiar aplicado, os demais valores não apresentaram resultados satisfatórios e são classificados como diagnóstico incorreto.

Na configuração 1, a função `traindm` é que obteve o melhor resultado, com a utilização de 40 e 20 nós nas camadas intermediárias. Porém, os sinais 102, 109 e 122 não obtiveram uma boa aproximação ao seu índice. Na configuração 2, a função de treino `trainlm` obteve o melhor resultado, com a presença de 5 valores característicos ao índice buscado.

Ao comparar as duas configurações, é possível determinar que a configuração 1 é a que possui um melhor resultado. Os testes realizados geraram um número de 90 resultados em cada configuração, sendo a primeira com 41 diagnósticos corretos e a segunda configuração com 22. Assim, de acordo com a Equação 22, a taxa de acerto da melhor configuração foi de 41,56%.

Como forma de classificação dos valores obtidos, foram selecionados os seguintes valores como os que possuem uma melhor resposta (Tabela 11). Em que foram encontrados, com exatidão, 6 dos 9 sinais testados, obtendo uma taxa de acerto de 66,67%, apresentando um erro de 33,33% em seu melhor resultado. Um resultado relativamente ruim, comparando aos valores de erro de diagnóstico (arritmia cardíaca) encontrados por Perales (2011) de 6,33% com 2 camadas ocultas e 16% com 1 camada oculta, e Rocha (2008) de 23% em sua configuração que utiliza os dados extraídos com a utilização de seu algoritmo, similar ao trabalho aqui apresentado.

Tabela 11. Melhor resultado encontrado na classificação dos sinais.

Sinais - Configuração 1								
102	109	112	115	117	119	122	209	220
Inconclusivo	Inconclusivo	Saudável	Saudável	Saudável	Patológico	Inconclusivo	Saudável	Saudável

A função de treino ‘`trainlm`’, com a técnica de otimização implementada pelo algoritmo de Levenberg-Marquardt, nas duas configurações, foi a que obteve um melhor resultado. Porém, o seu peso computacional é elevado em comparação as outras funções testadas nesse trabalho. Este fator também foi observado em Rocha (ano), que descreve mais detalhadamente o tempo para construir as redes e classificá-las. Com isso, a função de treino deve obedecer às capacidades técnica para a aplicação em questão, como em dispositivos que possuem pouca memória de processamento, proporcionando uma maior rapidez no processo. Os algoritmos do gradiente descendente exigem menos de memória,

e como o caso da função ‘traingdm’, que obteve o melhor resultado, atua em uma análise que vai além dos mínimos locais, ajustando os pesos da rede neural

7. Conclusão e Trabalhos futuros

7.1. Conclusão

Explorar sinais de ECG para estudar e detectar doenças cardíacas são avanços importantes na medicina. Um sinal com ruído mínimo é fundamental, para que as características e a classificação de várias patologias cardíacas sejam eficientes. Este trabalho propõe, em sua primeira parte, o uso de alguns filtros encontrados na literatura para analisar a possível redução do ruído original do ECG. Nos ajustes iniciais do sinal, a função *smooth* em sequência com a função *detrend* apresentaram resultados satisfatórios com eliminação da componente DC e ajuste da linha de base. Os filtros passa-alta e passa-baixa em cascata do tipo *FIR* proporcionaram uma redução de ruído que fornece uma detecção eficaz dos parâmetros. Como visualizado nas Figuras 6.14 e 6.15 o sinal foi alisado, eliminando as interferências pré-identificadas.

Com o pré-processamento bem estabelecido, o processo de extração das características do ECG também obteve taxas favoráveis. Com o algoritmo baseado em Pan-Tompkins (1987), a adaptabilidade procurada para identificar ciclos patológicos foi encontrada. Os processos que elevaram ao quadrado e derivaram o sinal proporcionaram um destaque ao pico R e uma eficaz identificação, mesmo em sinais patológicos de difícil interpretação. Após isso, em uma primeira análise, foi observado somente o complexo QRS, sendo os picos Q e S identificados com o uso de mínimos locais. Como esses picos são bem característicos, não houve tanta dificuldade em identificá-los. A taxa de acerto na identificação do complexo QRS foi de 98,09%. O restante do sinal, ou seja, a identificação dos picos P e T, também utilizou um sistema de localização similar dos picos anteriores, mas agora com o uso de máximos locais. Porém, apresentaram uma maior dificuldade de acerto, em virtude das características desses picos e sua dificuldade de identificação. Com a implementação de um sistema de Pop-up (janelas), o limiar onde acontecia a varredura para a detecção desses pontos máximos pode ser adaptado, melhorando a identificação e proporcionando uma interface com o usuário. Dentre os sinais utilizados como teste a taxa de acerto obtida foi de 96,29%, retornando uma boa taxa e solucionando o problema encontrado anteriormente.

A última etapa do projeto, a classificação dos sinais com uso de redes neurais artificiais, usou um sistema em que a saída desta era caracterizada pela presença ou não de patologias cardíacas no sinal. Foram analisadas e testadas duas configurações de matrizes, sendo uma com entradas alocadas em sequência e a outra segmentadas em 5 ciclos cardíacos. A configuração segmentada é a que apresentou um melhor resultado, com acerto de diagnóstico de 41,56% dentre todos os testes realizados. Esses dados foram obtidos a partir de uma rede neural do tipo feedforward e função de ativação de tangente hiperbólica ('tansig'). A função de ativação foi variada, proporcionando diversos resultados para análise, e a que obteve o melhor resultado foi a do gradiente descendente com momento (traingdm), com taxa de acerto de 66,67% na classificação dos dados. Como já era de esperado, o erro foi um pouco elevado (33,33%), mediante a utilização dos dados obtidos pelo algoritmo e sua quantidade (48 sinais), que contém erros de classificação e perante situações de entradas nunca vistas pela rede.

7.2. Trabalhos Futuros

Como sugestão de trabalhos futuros, a continuidade da linha de pesquisa, com o aperfeiçoamento do algoritmo, tornando-o mais robusto de forma a fazer uma detecção precisa e automática de todos os sinais de ECG. Outra sugestão consiste na implementação de uma interface mais complexa com o usuário, eliminando sua operação através de linhas de códigos, transformando-se em um programa mais visual e intuitivo. O conjunto dessas sugestões, tem por finalidade a implementação desse sistema em novas tecnologias, como aplicativos para celulares, 'smartwatches', etc.

Referências Bibliográficas

- AGUIAR, R., ANDREÃO, R., & BASTOS FILHO, T. F. (2006). Classificação e Não Supervisionada de Sinais de Eletrocardiograma. *Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo. Monografia apresentada em Fevereiro de 2006.*
- Andrade Filho, E. P.; Pereira, F. C. F. (2015). Anatomia Geral. 1ª ed. Sobral.
- Applegate, E. (2012). *Anatomia e fisiologia*. Elsevier Brasil.
- Ashkenazy, Y., Lewkowicz, M., Levitan, J., Moelgaard, H., Thomsen, P. B., & Saermark, K. (1998). Discrimination of the healthy and sick cardiac autonomic nervous system by a new wavelet analysis of heartbeat intervals. *Fractals*, 6(03), 197-203.
- Bagarrão, M. C. D. C. M. (2015). *Contribuições para a detecção automática de eventos presentes em sinais de eletrocardiograma* (Doctoral dissertation).
- Barth, F. (2017) Computação cognitiva e inteligência artificial: conceitos e aplicações em larga escala. Fonte, ano 14 nº 17.
- Batistella, J. C., & Dos Santos, E. M. (2017). REVISÃO DE FILTROS DIGITAIS BASEADOS NA TRANSFORMADA DISCRETA DE FOURIER UTILIZADOS PARA ESTIMAÇÃO FASORIAL. *Anais do Salão Internacional de Ensino, Pesquisa e Extensão*, 8(2).
- Beale, M. H., Hagan, M. T., & Demuth, H. B. (2008). *Neural Network Toolbox™ User's Guide*.
- Burrus, C. S., Primer, A., & Gopinath, R. A. (1998). Introduction to wavelets and wavelet transforms.
- Campos, L. F. A. D. A. (2018). Inteligência Artificial e Instrumentalização Digital no Ensino: A Semiformação na Era da Automatização Computacional.
- Carneiro, B. V., Pires, H. H. M., Nogueira, A. C. C., & Brick, A. V. (2012). Arritmias: fisiopatologia, quadro clínico e diagnóstico. *Revista de Medicina e Saúde de Brasília*, 1(2).
- Cunha, C. F. F. C. (2013) Aplicação da transformada wavelet na redução de ruídos em medições de descargas parciais. – Rio de Janeiro: UFRJ/COPPE.
- Daubechies, I. (1990). The wavelet transform, time-frequency localization and signal analysis. *IEEE transactions on information theory*, 36(5), 961-1005.
- Davis, Goode P. e Parks, Edward. (1987) *O corpo humano*. Alfragide: Ediclube. Vol. The Heart. The Living Pump.
- Digital Signal Processing Committee of the IEEE Acoustics, Speech, and Signal Processing Society, eds (1979). *Programs for Digital Signal Processing*. New York: IEEE Press,
- Drake, R. L., Mitchell, A. W., & Vogl, W. (2005). *Gray's anatomia para estudantes*. Elsevier Brasil.
- Figueredo, M. V. M., Nievola, J. C., Rogal, S. R., & Neto, A. B. (2008). Compression of Electrocardiogram Using Neural Networks and Wavelets. In *Computer and Information Science* (pp. 27-40). Springer, Berlin, Heidelberg.
- Frazão, A. C. Anatomia e fisiologia humana - sistema cardiovascular.

- Gigante, J. (2004). *Fisiologia do Coração*. Lisboa: Universidade Nova de Lisboa Faculdade de Ciências e Tecnologia, 2004.
- Goldberger A.L.; Amaral L.A.N.; Glass L.; Hausdorff J.M.; Ivanov P.Ch.; Mark R.G.; Mietus J.E.; Moody G.B.; Peng C.K. and Stanley H.E. (2000) “Components of a New Research Resource for Complex Physiologic”. *Circulation* 101(23): 215-220.
- Gonzalez, R. C., & Woods, R. E. (2000). *Processamento de imagens digitais*. Edgard Blucher.
- Gutierrez, C. E. C. “Eliminação do ruído por encolhimento de Wavelets”
- Guyton, A. C., Hall, J. E., & Guyton, A. C. (2006). *Tratado de fisiologia médica*. Elsevier Brasil.
- Habibi, A. (1995, November). Introduction to wavelets. In *Proceedings of MILCOM'95* (Vol. 2, pp. 879-885). IEEE.
- Haddadi, R., Abdelmounim, E., El Hanine, M., & Belaguid, A. (2014, April). Discrete wavelet transform based algorithm for recognition of QRS complexes. In *2014 International Conference on Multimedia Computing and Systems (ICMCS)* (pp. 375-379). IEEE.
- Haykin, S. (2001). *Redes Neurais Artificiais: Princípios e Práticas*. 2ª edição.
- J. Pan and W. Tompkins.(1985) “Real Time Algorithm detection for QRS”. *IEEE Trans. Eng. Biomed Eng*, 32(3): 230-236.
- Jaswal, G., Parmar, R., & Kaul, A. (2012). QRS detection using wavelet transform. *International Journal of Engineering and Advanced Technology (IJEAT)*, 1(6), 2249-8958.
- Lopes, C. D. (2005). *Análise de sinais de eeg utilizando a transformada wavelet discreta e as redes neurais artificiais* (Doctoral dissertation, Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, 2005).
- Magalhães, W. V. C. (2012). *Sistema de análise para eletrocardiograma*.
- Maleki M., Alizadehasl A. and Haghjoo M.(2017) .*Practical Cardiology*. Elsevier.
- Manzan, W. A. (2006)Utilização das transformadas wavelets na extração de características e no reconhecimento de padrão em um sinal de ECG. Universidade Federal de Uberlândia.
- Mehta, V.;Chaudhary, M. and Garg, D. (2016) “Generalized Noise reduction in ECG WAVES using optimal selection of Filters”. *International Journal of Engineering & Scientific Research*.
- Mendes, S. C. (2005) *Análise e Simulação de Algoritmos de Estimção*. Faculdade de Engenharia da Universidade do Porto
- Monteiro, F. (2008) *Sabenta de instrumentação biomédica*. Bragança: Intituto politécnico de Bragança – Departamento de Eletrônica, 2008.
- Moody G.B. and Mark R.G.(2001) “The impact of the MIT-BIH Arrhythmia Database”. *IEEE Eng in Med and Biol* 20(3): 45-50.
- Morais, C.(2009). *Fundação portuguesa de cardiologia*.
- Netter, F. H. (2018). *Netter atlas de anatomia humana*. Elsevier Brasil.

- OLIVEIRA, Hélio M. D. (2007) *Análise de sinais para engenheiros: uma abordagem via Wavelets*. Rio de Janeiro: Brasport.
- Oppenheim, A. V. (2010). *Sinais e sistemas*. Prentice-Hall.
- Pachauri, A., & Bhuyan, M. (2009). Robust detection of R-wave using wavelet technique.
- Pádua, F. (2008). O livro do coração: viver mais e melhor. *Alfragide (PT): Academia do Livro*.
- Perales, T. R. (2011) *Utilização de Redes Neurais Artificiais no Diagnóstico de Cardiopatias*.
- Pereira, L. V. C. (2015). *Análise de ECG no contexto de telemonitorização em insuficiência cardíaca* (Master's thesis).
- Proakis JG, Manolakis DG (1996) *Digital Signal Processing. Principles, Algorithms and Applications*. Prentice Hall Int., Inc.
- Rocha, T., Paredes, S., Carvalho, P., Henriques, J., Harris, M., Morais, J., & Antunes, M. (2010). A lead dependent ischemic episodes detection strategy using Hermite functions. *Biomedical Signal Processing and Control*, 5(4), 271-281.
- Rocha, V. B. (2008). Uma abordagem de wavelets aplicada a combinação de previsões: uma análise teórica e experimental. Dissertação Mestrado em Ciências. Universidade Federal do Paraná, Paraná, Brasil.
- Shea, M. J., Werns, S. W., & Lucchesi, B. R. (1985). Free radicals in ischemic myocardial injury. *Journal of free radicals in biology & medicine*, 1(2), 103-110.
- Sheng, Y. (1996). The transforms and applications handbook. *by AD Poularikas*, 747-827.
- Smith, S. W. (1997) *The Scientist and Engineer's Guide to Digital Signal Processing*. California Technical Pub 1.
- Teixeira, J. P. and Lopes, V. (2011) "Help system for medical diagnosis of the electrocardiogram". 1st International Conference on Serious Games and Applications for Health, 95-102.
- Teixeira, J. P., Batista, J., Toca, A., Gonçalves, J., & Pereira, F. G. (2009). Rede neuronal artificial para o reconhecimento de caracteres com interface gráfica. *Engenharia'09*.
- Toolbox, C. F. (2001). For Use with MATLAB;[user's Guide]. *The Mathworks Inc.(USA)*.
- Vaseghi, S. V. (2006). *Advanced Digital Signal Processing and Noise Reduction*. John Wiley & Sons.
- Webster, J. G., & Clark, J. W. (1997). *Medical instrumentation: application and design* (Vol. 200). John Wiley & Sons..
- Wei, J. T., Zhang, Z., Barnhill, S. D., Madyastha, K. R., Zhang, H., & Oesterling, J. E. (1998). Understanding artificial neural networks and exploring their potential applications for the practicing urologist. *Urology*, 52(2), 161-172.
- World Health Organization. (2018). ICD-11 for mortality and morbidity statistics (2018).
- Yang, W. Y. (2009). *Signals and Systems with MATLAB*. Springer.
- Yeh, Y. C., & Wang, W. J. (2008). QRS complexes detection for ECG signal: The Difference Operation Method. *Computer methods and programs in biomedicine*, 91(3), 245-254.

ANEXO I

Tabela de Registro de batimentos MIT-BIH

Legenda

Batida normal	.
Batida de bloco de ramo esquerdo	eu
Batida de bloco de ramo direito	R
Batida prematura atrial	UMA
Batimento prematuro atrial aberrante	uma
Batida prematura nodal (juncional)	J
Batida prematura supraventricular	S
Contração ventricular prematura	V
Fusão de batimento ventricular e normal	F
Onda de vibração ventricular	!
Batida de escape atrial	e
Batida de fuga nodal (juncional)	j
Batimento de escape ventricular	E
Ritmo estimulado	P
Fusão de batida ritmada e normal	f
Onda P não conduzida (APB bloqueado)	p
Batida inclassificável	Q

Sinal	.	eu	R	UMA	uma	J	S	V	F	!	e	j	E	P	f	p	Q
100	2239	-	-	33	-	-	-	1	-	-	-	-	-	-	-	-	-
101	1860	-	-	3	-	-	-	-	-	-	-	-	-	-	-	-	2
102	99	-	-	-	-	-	-	4	-	-	-	-	-	2028	56	-	-
103	2082	-	-	2	-	-	-	-	-	-	-	-	-	-	-	-	-
104	163	-	-	-	-	-	-	2	-	-	-	-	-	1380	666	-	18
105	2526	-	-	-	-	-	-	41	-	-	-	-	-	-	-	-	5
106	1507	-	-	-	-	-	-	520	-	-	-	-	-	-	-	-	-
107	-	-	-	-	-	-	-	59	-	-	-	-	-	2078	-	-	-
108	1739	-	-	4	-	-	-	17	2	-	-	1	-	-	-	11	-
109	-	2492	-	-	-	-	-	38	2	-	-	-	-	-	-	-	-
111	-	2123	-	-	-	-	-	1	-	-	-	-	-	-	-	-	-
112	2537	-	-	2	-	-	-	-	-	-	-	-	-	-	-	-	-
113	1789	-	-	-	6	-	-	-	-	-	-	-	-	-	-	-	-
114	1820	-	-	10	-	2	-	43	4	-	-	-	-	-	-	-	-
115	1953	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
116	2302	-	-	1	-	-	-	109	-	-	-	-	-	-	-	-	-
117	1534	-	-	1	-	-	-	-	-	-	-	-	-	-	-	-	-
118	-	-	2166	96	-	-	-	16	-	-	-	-	-	-	-	10	-
119	1543	-	-	-	-	-	-	444	-	-	-	-	-	-	-	-	-
121	1861	-	-	1	-	-	-	1	-	-	-	-	-	-	-	-	-
122	2476	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
123	1515	-	-	-	-	-	-	3	-	-	-	-	-	-	-	-	-
124	-	-	1531	2	-	29	-	47	5	-	-	5	-	-	-	-	-
200	1743	-	-	30	-	-	-	826	2	-	-	-	-	-	-	-	-
201	1625	-	-	30	97	1	-	198	2	-	-	10	-	-	-	37	-
202	2061	-	-	36	19	-	-	19	1	-	-	-	-	-	-	-	-
203	2529	-	-	-	2	-	-	444	1	-	-	-	-	-	-	-	4
205	2571	-	-	3	-	-	-	71	11	-	-	-	-	-	-	-	-
207	-	1457	86	107	-	-	-	105	-	472	-	-	10 5	-	-	-	-
208	1586	-	-	-	-	-	2	992	37 3	-	-	-	-	-	-	-	2
209	2621	-	-	383	-	-	-	1	-	-	-	-	-	-	-	-	-
210	2423	-	-	-	22	-	-	194	10	-	-	-	1	-	-	-	-
212	923	-	1825	-	-	-	-	-	-	-	-	-	-	-	-	-	-
213	2641	-	-	25	3	-	-	220	36 2	-	-	-	-	-	-	-	-
214	-	2003	-	-	-	-	-	256	1	-	-	-	-	-	-	-	2
215	3195	-	-	3	-	-	-	164	1	-	-	-	-	-	-	-	-
217	244	-	-	-	-	-	-	162	-	-	-	-	-	1542	260	-	-
219	2082	-	-	7	-	-	-	64	1	-	-	-	-	-	-	133	-
220	1954	-	-	94	-	-	-	-	-	-	-	-	-	-	-	-	-
221	2031	-	-	-	-	-	-	396	-	-	-	-	-	-	-	-	-
222	2062	-	-	208	-	1	-	-	-	-	-	21 2	-	-	-	-	-
223	2029	-	-	72	1	-	-	473	14	-	16	-	-	-	-	-	-
228	1688	-	-	3	-	-	-	362	-	-	-	-	-	-	-	-	-
230	2255	-	-	-	-	-	-	1	-	-	-	-	-	-	-	-	-
231	314	-	1254	1	-	-	-	2	-	-	-	-	-	-	-	2	-
232	-	-	397	1382	-	-	-	-	-	-	-	1	-	-	-	-	-
233	2230	-	-	7	-	-	-	831	11	-	-	-	-	-	-	-	-
234	2700	-	-	-	-	50	-	3	-	-	-	-	-	-	-	-	-