



CATÓLICA
ESCOLA SUPERIOR DE BIOTECNOLOGIA

PORTO

Sistemas de Deep-learning no apoio ao
rastreamento do Bloqueio do ramo direito através
de sinais ECG

por
Pedro Miguel da Silva Baptista Ribeiro

Novembro 2020



CATÓLICA
ESCOLA SUPERIOR DE BIOTECNOLOGIA

PORTO

Sistemas de Deep-learning no apoio ao rastreio do Bloqueio do ramo direito através de sinais ECG

Tese apresentada à Escola Superior de Biotecnologia da
Universidade Católica Portuguesa para obtenção do grau de Mestre em
Engenharia Biomédica

por

Pedro Miguel da Silva Baptista Ribeiro

Orientador: Prof. Doutor Pedro Miguel de Luís Rodrigues
Escola Superior de Biotecnologia, Universidade Católica Portuguesa

Novembro 2020

Resumo

Com o aumento exponencial dos casos de doenças cardiovasculares, a idealização de um algoritmo que possibilita a distinção de doenças é um grande aliado no diagnóstico.

O bloqueio do ramo direito, apesar de ser uma doença que pode nunca vir a apresentar sintomas, é um excelente indicador de possíveis doenças cardiovasculares futuras.

De forma a detetar o aparecimento do BBB nas suas fases iniciais, neste trabalho aplicou-se aos sinais ECG a Transformada *Wavelet* Discreta, o que permitiu extrair características na forma de energia, entropia e coerência de três níveis diferentes da decomposição do sinal.

A discriminação dos sinais foi realizada através da CNN no processo de validação cruzada *30-fold*.

A precisão na comparação entre o BBB e as outras doenças, presentes na mesma base de dados, cifrou-se entre 98,90% e 100% utilizando pequenas porções de sinal com pares de entrada/saída para as CNNs. No caso da medida energética as CNNs conseguiram precisões entre 91,14% e 66,51%, para a entropia, 91,68% e 64,31% e utilizando a coerência obteve-se uma precisão máxima de 90,83%.

Palavras-Chave: ECG; Bloqueio do ramo direito; Transformada de *Wavelet* Discreta; *Convolutional Neural Network*; Validação cruzada.

Abstract

With the exponential growing up in the number of cases for cardiovascular diseases, the idealization of an algorithm that can distinguish pathologies is a great ally in diagnosis.

The Right Bundle Branch Block, even though is a disease that can never present symptoms, it is an excellent indicator for future cardiovascular diseases.

In order to detect the appearance of the BBB in the early stages, in this work the Discrete Wavelet Transform was applied to the ECG signals, which allowed to extract characteristics such as energy, entropy and coherence from three different levels of signal decomposition.

The signal discrimination was performed through CNN in the 30-fold cross-validation process.

The comparison accuracy between BBB and other diseases, present in the database, ranged from 98,90% and 100% using small portions of signal as input/output pairs for the CNN. In the case of the energy measurement, CNN provided an accuracy between 91,14% and 66,51%, for the entropy, 91,68% and 64,31% and using coherences, a maximum accuracy of 90,83%.

Keywords: ECG; Right Bundle Branch Block; Discrete Wavelet Transform; Convolutional Neural Network; Cross-validation.

Agradecimentos

Com o finalizar desta dissertação, gostaria de agradecer a todos os que contribuíram para o meu sucesso académico.

Gostaria de agradecer ao Professor Doutor Pedro Rodrigues, por toda a sua disponibilidade e apoio durante este trabalho.

Agradeço à minha família por todo o suporte e motivação.

Quero deixar o meu agradecimento a toda a turma do mestrado, em especial à Daniela Paiva, Inês Sousa e Joana Sá, por todos os momentos que passamos juntos.

Quero agradecer à Rita Ferrinho, Rosa Araújo, Beatriz Frias, Elsa Miranda, Joana Oliveira, Marta Torres, Raquel Ribeiro e Teresa Faria, por uma licenciatura incrível.

Por fim, gostaria de agradecer à Ercília Ferreira, Filipa Silva, Nuno Machado e Rita Martins por toda a amizade, suporte e apoio.

Pedro Ribeiro

"Success is walking from failure to failure with no loss of enthusiasm."

Winston Churchill

Índice

1	Introdução	1
1.1	Motivação	1
1.2	Objetivo	1
1.3	Estrutura da Dissertação	2
2	Revisão Bibliográfica	3
2.1	O coração	3
2.1.1	Atividade elétrica do coração	4
2.2	Eletrocardiografia	4
2.2.1	Eletrocardiograma	5
2.2.2	Elétrodos e Derivações	5
2.3	Bloqueio do Ramo	8
2.3.1	Bloqueio do Ramo Direito	8
2.4	Estado da arte - Trabalho na área	8
3	Metodologia	11
3.1	Base de Dados	11
3.2	Transformada <i>Wavelet</i> Discreta	12
3.2.1	Energia	13
3.2.2	Entropia Shannon	13
3.2.3	Coerência	14
3.3	Contadores	14
3.4	<i>Deep Learning</i>	15
3.4.1	<i>Convolutional Neural Network</i>	15
3.4.2	Validação cruzada	16
3.5	Aplicação do Método	17
4	Resultados e Discussão	21
4.1	Resultados	21
4.2	Discussão	22

5	Conclusões e Trabalho Futuro	25
5.1	Satisfação dos Objetivos	25
5.2	Trabalho Futuro	25
	Bibliografia	27
A	Resultados conseguidos nos contadores e na CNN	31
A.1	Resultados dos contadores para os vários níveis da Energia	31
A.2	Resultados para os vários níveis dos contadores na Entropia	32
A.3	Resultados dos contadores para os vários níveis da Coerência	32

Lista de Figuras

2.1	Anatomia do coração [2].	3
2.2	Sistema de condução do coração [2].	4
2.3	Demonstração da colocação dos elétrodos no corpo [3].	5
2.4	Sistema de Einthoven [3].	6
2.5	Sistema de Goldberger [3].	7
2.6	Sistema de Wilson [3].	7
2.7	ECGs do Bloqueio do Ramo Direito [8].	8
3.1	Esquema da transformada wavelet.	13
3.2	Esquema usado para os contadores.	15
3.3	Validação cruzada.	17
3.4	Esquema da CNN utilizada neste trabalho.	18
3.5	Diagrama de fluxo	19
4.1	Gráfico das precisões finais.	21
4.2	Gráfico das precisões finais.	22

Lista de Tabelas

2.1	Critérios para a identificação do Bloqueio de Ramo Direito [4].	8
2.2	Metodologia do estado de arte com a respectiva precisão.	9
3.1	Número de ECGs por diagnóstico.	12
3.2	Tipos de camadas na CNN e respectivas saídas.	18
A.1	Resultados obtidos nos contadores para a totalidade das derivações, nos 3 níveis da decomposição, na Energia (S = BBB contabilizado mais vezes, N = BBB contabilizado menos vezes).	31
A.2	Resultados demonstrados pelos contadores para a totalidade das derivações, nos 3 níveis da decomposição, na Entropia (S = BBB contabilizado mais vezes, N = BBB contabilizado menos vezes).	32
A.3	Resultados adquiridos nos contadores para a totalidade das derivações, nos 3 níveis da decomposição, na Coerência (S = BBB contabilizado mais vezes, N = BBB contabilizado menos vezes).	32

Abreviaturas e Símbolos

BBB	Bloqueio do Ramo
CNN	<i>Convolutional Neural Network</i>
CV	Validação cruzada
DL	<i>Deep Learning</i>
DWT	Transformada <i>Wavelet</i> Discreta
ECG	Eletrocardiografia
RBBB	Bloqueio do Ramo Direito
ReLU	<i>Rectified Linear Unit</i>

Introdução

1.1 Motivação

A realização deste trabalho teve por base três motivos fundamentais.

O primeiro teve a ver com o facto de a população estar cada vez mais idosa, o que leva a um grande aumento no número das doenças cardiovasculares.

O segundo deve-se à constatação de que os sintomas da doença não são sempre detetáveis, em alguns casos as pessoas podem ter BBB por anos e nunca terem apresentado qualquer tipo de sintoma.

O último, residiu no facto de o BBB em si poder não ser muito grave e a doença pode ser usada como um aviso para outro tipo de doenças cardiovasculares que apresentam uma gravidade muito superior.

Os motivos supra-referidos incentivaram a criação de uma ferramenta capaz de detetar a doença e prevenir possíveis consequências inerentes, conseguindo assim salvar mais vidas.

1.2 Objetivo

O objetivo deste trabalho consistiu no desenvolvimento de um algoritmo com capacidade de detetar eventos de bloqueio do ramo direito e de forma a conseguir diferenciar BBB das outras doenças. Para que fosse possível a deteção automática de eventos de BBB, extraiu-se partes do sinal ECG característicos da doença. A seguir aplicou-se uma decomposição multi-banda a esses segmentos através da DWT de forma a obter padrões típicos da doença. Por último, as CNNs foram treinadas com os dados extraídos de forma a aprenderem a detetar eventos típicos de BBB.

1.3 Estrutura da Dissertação

Esta dissertação é constituída por 5 capítulos.

No Capítulo 1 é apresentada a introdução da dissertação. Este capítulo é composto pela motivação, objetivos e estrutura da dissertação.

No Capítulo 2 é feita uma revisão bibliográfica em que é apresentado o coração e a sua atividade elétrica. Adicionalmente, também é introduzida a doença em estudo, o sinal biomédico e o estado da arte.

O Capítulo 3 é dedicado à base de dados e à metodologia. Neste capítulo são referidas as informações sobre a base de dados e a metodologia utilizada. Para a Metodologia são referidos os métodos usados, assim como as métricas.

No Capítulo 4 mostram-se os resultados e a discussão dos mesmos.

No Capítulo 5 referem-se às conclusões e trabalhos futuros.

Revisão Bibliográfica

2.1 O coração

O coração é um órgão muscular que se encontra no mediastino [1]. Anatomicamente, o coração é constituído por duas aurículas e dois ventrículos, também possui uma válvula mitral e uma tricúspide, que dividem as aurículas dos ventrículos e as válvulas aórtica e pulmonar que fazem com que o sangue possa sair do coração de forma correta [1, 2]. A figura 2.1 ilustra a anatomia do coração.




Figura 2.1: Anatomia do coração [2].

Relativamente à circulação do sangue, o coração distribui o sangue através de variações de pressão, o que faz com que o sangue circule de uma cavidade para a outra [2].

2.1.1 Atividade elétrica do coração

Para que ocorra a circulação correta do sangue, o sistema de condução ilustrado na figura 2.2, constituído pelo nó sinusal, nó auriculoventricular, feixe de his e pelas fibras de Purkinje, gera sinais elétricos que vão fazer com que o miocárdio contraia [1].




Figura 2.2: Sistema de condução do coração [2].

2.2 Eletrocardiografia

Eletrocardiografia é o processo no qual se produz o eletrocardiograma (ECG). Neste processo é representado um gráfico de voltagem em relação ao tempo que capta a atividade elétrica do coração. O ECG representa os potenciais de ação de cada célula que é estimulada no coração. A cada ciclo cardíaco, o ECG vai registar um conjunto de ondas. A primeira onda é referente à onda P, que é a responsável pela despolarização das aurículas, de seguida vem o complexo QRS que está relacionado à despolarização ventricular, por fim a onda T que está relacionada com a repolarização dos ventrículos. A captação dos ciclos é feita através de elétrodos e recolhido pelo eletrocardiografo [3, 4].

2.2.1 Eletrocardiógrafo

Eletrocardiógrafo é uma máquina que regista o sinal ECG através de eléttodos que estão ligados ao aparelho. Após a recolha do sinal, o eletrocardiógrafo mede e calcula as diferenças de potencial das derivações. Estas diferenças correspondem diretamente à atividade elétrica do coração. No final dos cálculos, o sinal ECG é exibido no ecrã, digitalizado e/ou impresso [5].

Recolher o sinal é um processo seguro e indolor, contudo é possível que algumas pessoas apresentem alguma irritação devido à pasta ou gel que foram usados nos eléttodos. Esta irritação desaparece sem haver a necessidade de tratamento [6].

2.2.2 Eléttodos e Derivações

O sinal elétrico do coração é captado na superfície do corpo através de eléttodos. Um eléttodo é colocado em cada membro e outros seis são colocados na zona do peito como demonstra a figura 2.3. Cada eléttodo serve para dar um perspetiva do coração, através do sinal elétrico que chega à superfície do corpo onde o eléttodo está colocado, tornando-se possível visualizar os ciclos cardíacos [7].




Figura 2.3: Demonstração da colocação dos eléttodos no corpo [3].

Com um total de 12 *leads* e 10 eléttodos, os ECGs apresentam 6 derivações relativamente às 4 extremidades do corpo, estas derivações são *standard* ou aumentadas.

As 3 derivações *standard*, mais conhecido como sistema de Einthoven, apresentam um ponto de vista específico do coração, ou o seu ângulo de orientação, como ilustra a figura 2.4. O *Lead I* é estabelecido fazendo com que o braço esquerdo seja positivo e o braço direito negativo, com um ângulo de orientação de 0° . O *Lead II* é formulado fazendo com que as pernas sejam positivas e o braço direito negativo, tendo assim um ângulo de orientação de 60° . O *Lead III* é concebido fazendo com que as pernas sejam positivas e o braço esquerdo negativo, tornando o ângulo de orientação 120° [3].




Figura 2.4: Sistema de Einthoven [3].

As 3 derivações adicionais, mais conhecido como sistema de Goldberger, formam um sistema diferente do referido anteriormente, neste um *lead* é escolhido como positivo e o resto negativo, como demonstrado na figura 2.5. O *Lead aVL* é idealizado fazendo com que o braço esquerdo seja positivo e os outros negativos, com um ângulo de orientação de -30° . O *Lead aVR* é elaborado fazendo com que braço direito seja positivo e as outras extremidades negativas, tendo assim um ângulo de orientação de -150° . O *Lead aVF* é construído fazendo com que as pernas sejam positivas e o resto dos membros negativos, fazendo com que o ângulo de orientação seja 90° [3].

Os *leads* restantes, são obtidos com elétrodos colocados no peito. Também conhecido como sistema de Wilson, as derivações unilaterais (de V_1 a V_6) são colocadas no plano horizontal do peito em zonas específicas do peito, como está representado na Figura 2.6. A colocação dos elétrodos nesta zona vai fazer com que exista uma nova perspectiva do coração em vários ângulos. No momento da colocação destes elétrodos, o processo tem de ser feito com um cuidado extremo, uma vez que




Figura 2.5: Sistema de Goldberger [3].

pode haver uma interpretação incorreta do diagnóstico [3].




Figura 2.6: Sistema de Wilson [3].

2.3 Bloqueio do Ramo

O Bloqueio do Ramo (BBB) é uma doença cardiovascular que afeta o sistema de condução. Nesta doença, há o bloqueio de um dos ramos. Essa obstrução pode ser completa, não passa nenhum sinal elétrico, ou incompleta, o sinal elétrico passa com algum atraso [3].

2.3.1 Bloqueio do Ramo Direito

O Bloqueio do Ramo Direito (RBBB) acontece quando o sinal elétrico é obstruído no ramo direito afetando o ECG, como pode ser visto na figura 2.7. Este acontecimento vai fazer com que a despolarização do ventrículo esquerdo esteja quase completa, quando se iniciar a despolarização do ventrículo direito. Este atraso faz com que haja um aumento na duração da fase de despolarização ventricular [3].




Figura 2.7: ECGs do Bloqueio do Ramo Direito [8].

Esta doença consegue ser identificada com o auxílio dos *leads* V_1 , V_2 , V_5 e V_6 . Na Tabela 2.1 estão apresentados os critérios utilizados para a identificação do RBBB.

Tabela 2.1: Critérios para a identificação do Bloqueio de Ramo Direito [4].

Critérios usados para o Bloqueio do ramo direito	
QRS	duração $\geq 0,12s$
Leads V_1 e V_2	QRS em formato de M ou na forma de "orelhas de coelho"; por vezes um pico R extenso
Leads V_5 e V_6	alargamento da onda S

2.4 Estado da arte - Trabalho na área

A tabela 2.2 apresenta um conjunto de trabalhos de revisão do estado da arte na detecção de BBB.

Tabela 2.2: Metodologia do estado de arte com a respetiva precisão.

#	Base de dados	Resultado	Metodologia
[9]	MIT-BIH Arrhythmia database	RBBB vs Controlo 88,8%	Huang <i>et al.</i> usaram os batimentos do coração para criar um processo de classificação. Este trabalho consistiu em três fases: pré-processamento, extração de características e classificação. O processo consistiu na deteção dos picos R e separação em grupos para serem classificados por três classificadores distintos. Os grupos foram: controlo e bloqueio do ramo esquerdo, controlo e bloqueio do ramo direito e bloqueio do ramo direito e esquerdo, os processos de classificação, aplicados um por cada grupo, foram distâncias mínimas, discriminante linear e SVM linear respetivamente.
[10]	PTB Diagnostic ECG database	RBBB vs Controlo 100%	Ali <i>et al.</i> investigaram a classificação do bloqueio de ramo através de uma rede HMLP (<i>Hybrid Multilayered Perceptron</i>). Neste tipo de rede para além de haver as ligações entre o input, camadas escondidas e output, também existia uma ligação que começava no input e ia diretamente para o output.
[11]	PTB Diagnostic ECG database	RBBB vs Controlo 100%	Ali <i>et al.</i> desenvolveram um algoritmo que detetava e distinguia o bloqueio do ramo direito do bloqueio do ramo esquerdo e também do grupo de controlo. Neste trabalho foram extraídas características do domínio temporal para serem utilizadas no input da rede que vai fazer a classificação. A rede neuronal utilizada foi uma <i>Multilayered Perceptron Network</i> . Esta rede consistiu numa camada de input, uma ou várias camadas escondidas e uma camada de output. A sua classificação foi feita através de cálculos do peso e da ligação que cada nó fez.
[12]	MIT-BIH Arrhythmia database	RBBB vs Controlo 99,59%	Ranaware e Deshpande desenvolveram um algoritmo que detetou o bloqueio com base na transformada wavelet discreta com a classificação através de uma rede neuronal artificial e SVM. O algoritmo consistiu em três fases. A primeira foi o pré-processamento com a normalização e filtração do sinal. A segunda fase foi a extração das características que foram usadas como input para os classificadores. A última fase foi a classificação do sinal de entrada numa rede neuronal artificial e numa SVM.
[13]	PTB Diagnostic ECG database	BBB vs Outras Doenças 93,65%	Ali <i>et al.</i> desenvolveram um sistema de diagnóstico automático para doenças cardiovasculares. Neste trabalho foi feita a extração de características tais como localização, amplitude e largura de cada uma das ondas do sinal ECG. Por fim, foi usado um algoritmo de classificação SVM por causa do número reduzido de características extraídas.
[14]	PTB Diagnostic ECG database	BBB vs Outras Doenças 97,78%	Neste artigo, Tripathy e Dangapat apresentaram uma técnica nova para estimar o diagnóstico usando várias derivações do eletrocardiograma. Para classificar as características obtidas foram usadas <i>multilayer perceptron</i> e <i>support vector machine</i> em todas as doenças estudadas neste trabalho.

Metodologia

3.1 Base de Dados

A base de dados usada foi uma coleção de dados da *PTB Diagnostic ECG Database* [15, 16], com as seguintes características:

- 16 canais de entrada (14 para ECGs, 1 para a respiração, 1 para a linha de tensão)
- Tensão de entrada: ± 16 mV
- Largura de banda: 0 - 1 kHz
- Tensão máxima de ruído: 10 μ V
- Registo online da resistência da pele
- Registo do nível de ruído feito durante a recolha do sinal

A base de dados contem 549 registos com idades compreendidas entre os 17 e 87 anos. Cada registo inclui os 12 *leads* convencionais (I, II, III, aVR, aVL, aVR, V1, V2, V3, V4, V5 e V6) e também 3 derivações dos eixos (V_x , V_y e V_z). Cada um destes sinais tem uma frequência de amostragem de 1000 Hz, com um tempo de recolha de 10 segundos e 16 bit de resolução num intervalo de $\pm 16,384$ mV.

A Tabela 3.1 apresenta a distribuição dos ECGs por cada doença presente na base de dados.

Tabela 3.1: Número de ECGs por diagnóstico.

Diagnóstico	Número de ECGs
Bloqueio do Ramo (BBB)	17
Cardiomiopatia (Cm)	20
Grupo de controlo (HC)	80
Miocardite (Mc)	4
Hipertrofia do Miocárdio (MH)	2
Enfarte do Miocárdio (MI)	367
Doenças Valvulares (VHD)	6
Arritmias (Ar)	16

3.2 Transformada *Wavelet* Discreta

A transformada *Wavelet* é uma ferramenta que separa as frequências em dois grupos, baixas e altas frequências. A obtenção da Transformada *Wavelet* Discreta (DWT) é composta por duas fases, a convolução do sinal de entrada e pelo processo subamostragem [17, 18].

$$y1[n] = \sum_k^{m-1} a[k]x[2n-k] \quad (3.1)$$

$$y2[n] = \sum_k^{m-1} d[k]x[2n-k] \quad (3.2)$$

Nas equações 3.1 e 3.2, estão representados os *outputs*. O $a[k]$ é a resposta impulsional do filtro passa-baixo, o $d[k]$ é a resposta impulsional do filtro passa-alto e o $x[2n-k]$ é o sinal de entrada com atraso e declinação de fator 2 [17, 18].

$$W_{y1}[j,k] = \sum_n W_{y1}[j-1,n]a[2k-n] \quad (3.3)$$

$$W_{y2}[j,k] = \sum_n W_{y1}[j-1,n]d[2k-n] \quad (3.4)$$

A transformada *Wavelet* tem vários níveis, cada um desses níveis teve a sua origem no *output* do filtro passa baixo (eq. 3.1). As equações 3.3 e 3.4 apresentam os coeficientes de detalhe (W_{y2}) e de aproximação (W_{y1}) para j níveis de decomposição. O esquema na figura 3.1 é representativo do

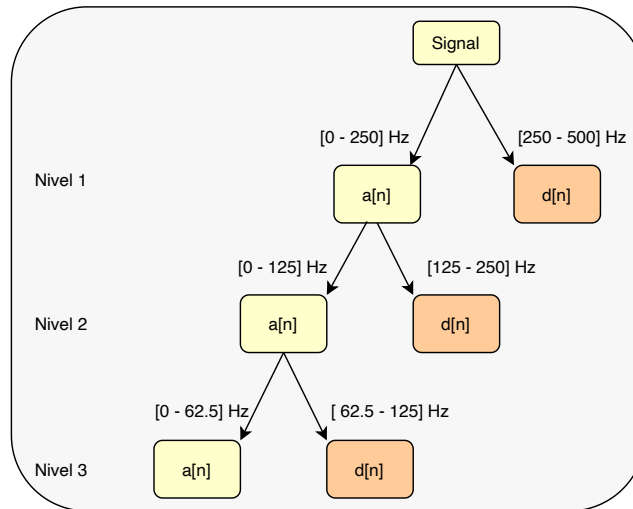


Figura 3.1: Esquema da transformada wavelet.

algoritmo da transformada *Wavelet* que se usou neste trabalho, em que o nível máximo foi 3, com a *wavelet*-mãe usada *sym7*. Após a separação do sinal, pelas frequências, os *outputs* que resultam deste processo têm os nomes aproximação ($a[n]$) e detalhe ($d[n]$). As aproximações são os sinais de saída provenientes do filtro passa-baixo, equação 3.1. Os detalhes são os sinais de saída do filtro passa-alto na equação 3.2.

3.2.1 Energia

O Teorema de Parseval relaciona a energia do sinal com a energia de cada componente e os coeficientes da wavelet [18].

$$E_i = \sum_{n=0}^{N-1} x[n]^2 \quad (3.5)$$

onde, $nivel \rightarrow i = (1, 2, 3)$. Na equação 3.5, a energia é calculada como sendo o somatório do sinal ao quadrado, em que n começa no início do vetor e vai até ao penúltimo valor do comprimento do vetor [19].

3.2.2 Entropia Shannon

Entropia é a medida para encontrar a efetividade de compressão dos algoritmos [19].

$$ES_i = - \sum_{n=0}^{N-1} x_i^2[n] \log(x_i^2[n]) \quad (3.6)$$

onde, $nivel \rightarrow i = (1, 2, 3)$.

3.2.3 Coerência

Coerência é definida como sendo a propriedade de partes de algo que permitem que se juntam de forma natural. Neste trabalho, a coerência foi obtida através de um conjunto de 3 equações.

A primeira função implementa uma convolução circular diretamente no domínio temporal. Esta função é aplicada no domínio de Fourier, em que para computar a *wavelet* foi necessário usar a Transformada Discreta de Fourier Inversa.

$$Co1_i[n] = \frac{1}{N} \sum_{k=0}^{N-1} H_{j,k} e^{\frac{i2\pi nk}{N}} \quad (3.7)$$

onde, $nivel \rightarrow i = (1, 2, 3)$. A segunda função aplica a variância à sobreposição máxima da função 3.7, dando como resultado de saída uma estimativa imparcial da variância da *wavelet*.

$$Co2_i[n] = \frac{1}{N} \sum_{n=0}^{N-1} (Co1_i[n])^2 \quad (3.8)$$

em que, $nivel \rightarrow i = (1, 2, 3)$. A última equação consistiu no somatório da função 3.8 ao quadrado.

$$Co_i[n] = \sum_{n=0}^{N-1} (Co2_i[n])^2 \quad (3.9)$$

onde, $nivel \rightarrow i = (1, 2, 3)$.

3.3 Contadores

Dado que eventos de BBB podem ser esporádicos, foram definidos intervalos de distribuição para cada uma das características retiradas a partir da DWT. Os intervalos selecionados foram superior à média, inferior à média e por último máximo/mínimo. A esses intervalos de distribuição associou-se os parâmetros retirados de toda a base de dados, de forma a fazer uma avaliação à sua totalidade. Imediatamente após foram introduzidas duas condições. A primeira condição foi se contabilizaram mais parâmetros para o grupo BBB em relação às outras patologias, dentro dos intervalos definidos, caso a condição fosse obedecida dava-se início à análise estatística. Se a diferença fosse significativa, o intervalo de distribuição era um intervalo de interesse, uma vez que o grupo BBB tinha manifestado mais em relação aos grupos restantes, com este limitador. Caso alguma destas condições não fossem cumpridas, o intervalo de distribuição que tinha sido definido não apresentava qualquer tipo de interesse, visto que, não conseguiu distinguir a patologia a ser estudada em relação às restantes. A figura 3.2 apresenta o esquema de todas as etapas referidas anteriormente para os contadores.

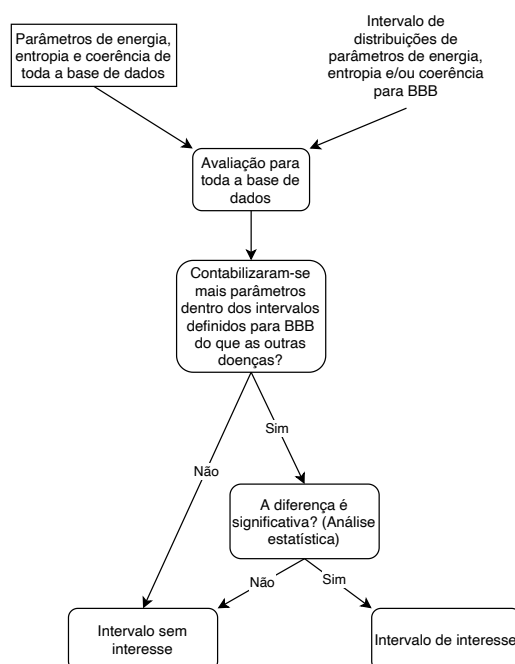


Figura 3.2: Esquema usado para os contadores.

3.4 Deep Learning

Deep Learning (DL) faz parte da família de *machine learning* baseado em métodos de redes neurais artificiais, ou seja, o motivo de usar este tipo de metodologia serve para tentar simular a forma de como o nosso cérebro consegue reconhecer os objetos e padrões que nos rodeiam [20, 21].

DL tem três formas de aprendizagem que são a supervisionada, a semi-supervisionada e a não supervisionada [20, 21].

Neste trabalho foi só usada a aprendizagem supervisionada. Neste tipo de *Machine learning*, o computador vai ter de dar resposta aos dados que foram colocados. Para que seja possível dar resposta aos dados aplicados, é idealizada uma matriz de treino que abrange dados sobre as doenças presentes na base de dados e um vetor *target* que concede a resposta dessa matriz [20, 21].

3.4.1 Convolutional Neural Network

Dentro da DL, a *Convolutional Neural Network* (CNN) é um tipo de classificador particularmente útil para encontrar padrões, objetos, caras e cenários em imagens. Para além da sua grande popularidade em imagem, a CNN também consegue fazer classificações diretamente de vídeos, texto ou som [22, 23].

Como a CNN faz parte da DL, ela pertence à classe das redes neurais artificiais, ou seja, a forma como o código classifica aproxima-se ao processo de classificação que o cérebro usa [21].

Para que ocorra a classificação, a CNN utiliza o que se chama de camadas (*layers*), uma vez que este algoritmo está relacionado com um tipo de aprendizagem profunda, classificar algum objeto na CNN envolve a participação de várias camadas. Existem três posições diferentes para os *layers*, as *input layers*, onde ficam os dados que o programador quer analisar como por exemplo um sinal. A segunda posição chama-se *hidden layers*, nesta camada a CNN altera os dados de forma a conseguir aprender características específicas. A última posição chama-se *output layer*, esta camada é o resultado a aprendizagem das *layers* anteriores, apresentando uma classificação dos dados que tinham sido introduzidos na *input layer* [22].

De forma a alterar os dados apresentados e aprender novas *features*, as camadas fazem operações diferentes ao sinal. Os três tipos de camadas mais comuns são: *Convolution*, *Rectified linear* e *Pooling*. A *Convolution* aplica uma série de filtros convolucionais para ativar certas características, estes filtros percorrem o sinal introduzido pelo programador e através de um cálculo matemático cria um novo conjunto de valores. A *Rectified linear unit* (ReLU) aplica um threshold fazendo com que os valores negativos passem a zeros e atribui o valor de x aos restantes, este tipo de camada também pode ser referida de ativação, uma vez que só as características que foram ativas é que passam para as camadas seguintes. Na *Pooling*, existe uma simplificação do *output* através de uma diminuição do número de amostras, reduzindo assim o número de parâmetros que a rede necessita de aprender [22–24].

Após aprender as novas *features*, a CNN passa para a fase de classificação. Nesta fase a classificação é feita através de uma camada de seu nome *fully connected layer*, esta camada vai ter de saída um vetor de N dimensões em que N representa o número de classes que a rede pode classificar, no caso deste trabalho, o número de classes eram duas, se é BBB ou não é BBB [22].

3.4.2 Validação cruzada

Validação cruzada (CV) é uma técnica para avaliar a performance de um algoritmo de *machine learning* através de previsões de novos dados que ainda não foram treinados [25, 26]. Este tipo de técnica funciona através de divisão dos dados em grupos, um grupo de treino e outro de teste. Esta divisão vai aleatoriamente separar os dados originais, fazendo com que o grupo de teste nunca seja o mesmo [25, 26]. A figura 3.3 ilustra o processo de CV explicado anteriormente.

A separação dos dados é feita com o uso de certas técnicas de CV. A técnica usada nesta dissertação foi a *k-fold*. Esta técnica consiste na divisão dos dados em k grupos aleatórios, onde um desses grupos é usado para validar o modelo treinado dos grupos restantes. O processo vai ser repetido k vezes, alterando sempre o grupo que valida o modelo [25, 26].

Para o número de rondas a que os dados foram sujeitos, foi escolhido 30 *folds*. Este número foi escolhido por causa da estimativa tendenciosa criada pelo computador, uma vez que este número foi relativamente elevado, o facto de poder aparecer alguma ronda com uma precisão muito diferente das restantes, não vai ter um grande impacto no resultado final da precisão.

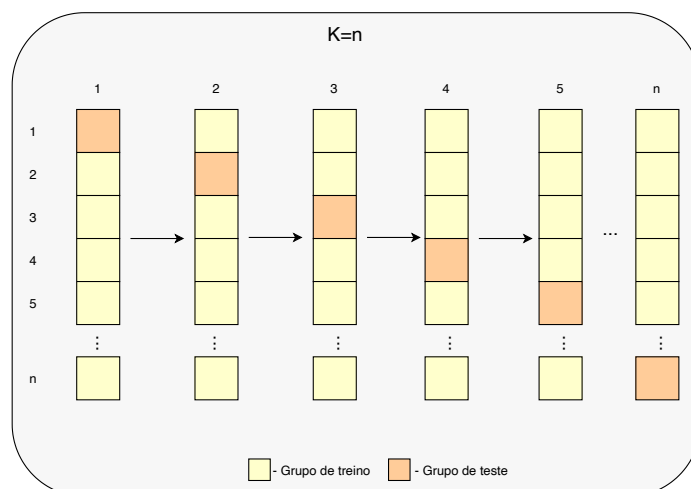


Figura 3.3: Validação cruzada.

3.5 Aplicação do Método

O estudo foi realizado a partir do software MATLAB[®]2019b e pode ser dividido em três pontos chave:

- Janelamento dos ECGs da base de dados, normalização dos segmentos, extração das características, utilizando a Transformada *Wavelet* Discreta;
- Criação de intervalos a partir dos valores que resultaram da extração das características dos padrões do BBB, utilizar contadores com os intervalos de forma a limitar os valores que iam ser contabilizados e posterior análise estatística;
- Classificação com CNN;

Foram extraídos os padrões do BBB e foi feito o janelamento à base de dados, na qual cada janela correspondia a 0,156 segundos. Seguidamente, foi aplicada a Transformada *Wavelet* Discreta com o objetivo de extrair as características energia, entropia e coerência, neste estudo a extração das características foi feita até ao nível 3 de decomposição.

De seguida, foram idealizados os intervalos com o auxílio das características dos eventos de BBB e feitas as análises estatísticas com os contadores. As tabelas A.1, A.2 e A.3 dos anexos demonstram os resultados obtidos nos contadores com os intervalos retirados dos respetivos eventos da doença em estudo. Nas tabelas, o BBB foi comparado com as outras doenças nos intervalos superior à média, inferior à média e máximo/mínimo. Esta distinção foi feita para os três níveis de decomposição do sinal combinados e também separados. Os resultados das tabelas foram dos valores de prova associados aos contadores, em que o "S" significava que o BBB foi contabilizado mais vezes e que era possível distinguir as duas doenças, enquanto que o "N" apresentava uma contagem do BBB inferior à patologia que estava a ser comparado. O teste estatístico usado foi o Kruskal-Wallis.

No final, para verificar a precisão dos modelos aplicados, foram apresentadas como pares de entrada/saída das CNNs, num processo de validação cruzada 30 *fold*, matrizes constituídas por parâmetros de energia, entropia, coerência e de segmentos de sinal ECG de 0,156 segundos. O segmento correspondeu à janela do parâmetro que foi retirado a partir do intervalo de interesse. As CNNs foram utilizadas como classificadores neste processo de validação cruzada.

O esquema utilizado para as CNNs neste trabalho, com as respectivas camadas, é apresentado na figura 3.4. As CNNs eram constituídas por 8 layers e a tabela 3.2 mostra a estrutura dessas camadas

Tabela 3.2: Tipos de camadas na CNN e respectivas saídas.

Tipo de camada	Saída
<i>ImageInputLayer</i>	1, 156, 1 ou 1, 1, 1
<i>Convolution2DLayer</i>	1, 155, 16 ou 1, 1, 16
<i>ReLULayer</i>	1, 155, 16 ou 1, 1, 16
<i>FullyConnectedLayer</i>	1000
<i>FullyConnectedLayer</i>	1000
<i>FullyConnectedLayer</i>	2
<i>SoftmaxLayer</i>	2
<i>ClassificationOutputLayer</i>	2

Neste trabalho foram experimentados três algoritmos de treino (sgdm, adam e rmsprop) com 1000 épocas e 8 iterações por época.

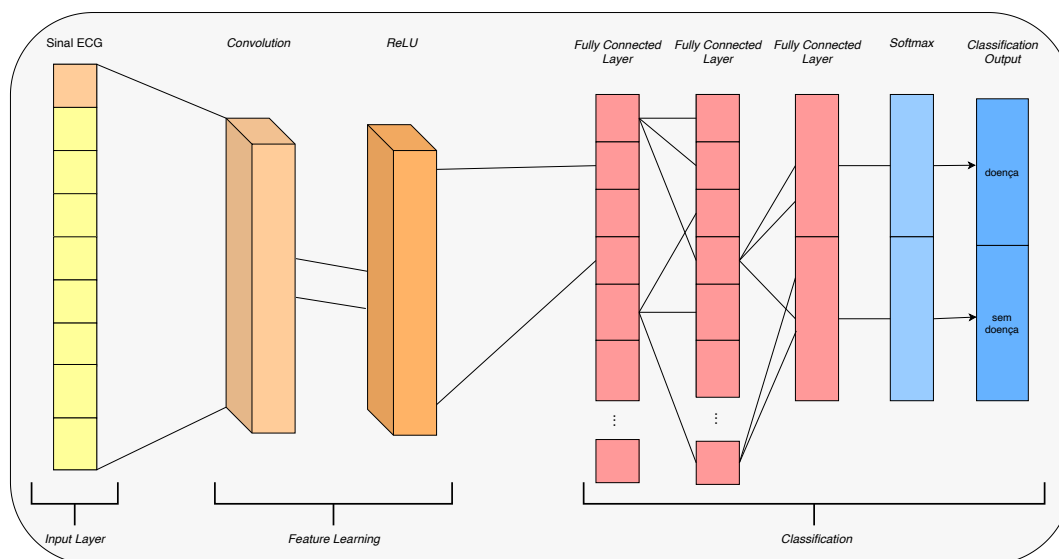


Figura 3.4: Esquema da CNN utilizada neste trabalho.

A figura 3.5 apresenta o diagrama de fluxo que resume toda a metodologia aplicada neste estudo para a obtenção dos resultados finais.

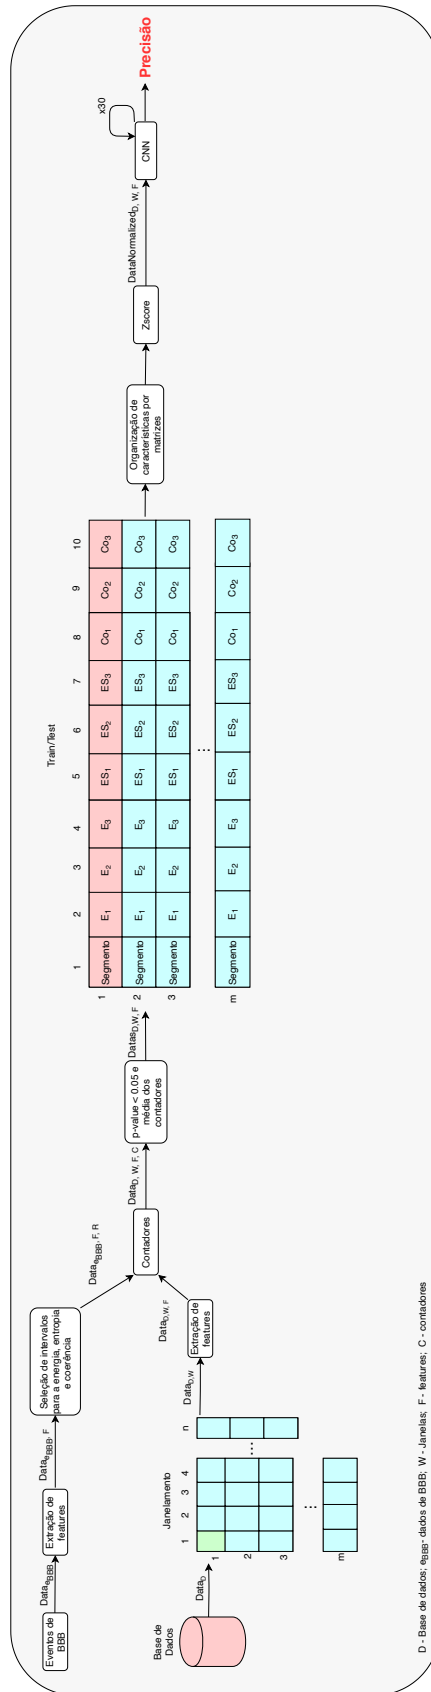


Figura 3.5: Diagrama de fluxo

Resultados e Discussão

4.1 Resultados

O gráfico na figura 4.1 apresenta os resultados finais da precisão para as validações cruzadas com as CNNs para os parâmetros segmento e energias do nível 1 ao 3.




Figura 4.1: Gráfico das precisões finais.

O gráfico na figura 4.2 apresenta os resultados finais da precisão das validações cruzadas com as CNNs para as características entropia e coerência dos níveis 1 ao 3.




Figura 4.2: Gráfico das precisões finais.

4.2 Discussão

Ao observar as figuras 4.1 e 4.2, verifica-se que as precisões obtidas pelas CNNs tiveram os melhores resultados na metodologia aplicada ao segmento, com uma precisão mínima de 98,91%.

No que diz respeito às características que foram retiradas na Wavelet, a E_1 apresentou os melhores resultados quando o BBB foi comparado com a Mc e MH, demonstrando precisões de 90,88% e 90,89% respectivamente. As precisões mínimas obtidas pela energia no nível 1 foram registados para o BBBvsHc e o BBBvsMI, com 66,51%. Para a E_2 , o resultado máximo foi de 90,58% obtido no BBBvsMc, o resultado mínimo apresentado nesta característica foi de 66,51% no BBBvsMI. A E_3 exibiu uma classificação máxima de 91,14% para o modelo BBBvsMc e uma precisão mínima de 66,51%, expresso no BBBvsMI e no BBBvsHC.

A ES_1 revelou as melhores precisões nos modelos BBBvsMH e BBBvsMc com um resultado de 90,89%. No ES_2 , o BBBvsMc alcançou a precisão máxima de 90,71% e uma validação cruzada mínima de 66,51% para o BBBvsMI. No caso da característica ES_3 , os resultados variaram entre 91,68% (BBBvsMc) e 66,51% (BBBvsMI).

A última *feature* utilizada neste trabalho foi a coerência. No que diz respeito à Co_1 , os modelos com as precisões máximas foram os BBBvsMH (90,83%) e BBBvsMc (90,77%), para o mesmo nível da coerência, o modelo que obteve os resultados menos significativos foi o BBBvsMI com um valor de 66,44%. Na Co_2 , a precisão máxima de 85,43% pertence ao modelo BBBvsMc. No caso da Co_3 , as classificações máximas foram obtidas no BBBvsMc (79,97%) e com o BBBvsMH (79,90%), a precisão mínima foi nos modelos BBBvsMI e BBBvcHC, com o resultado de 66,51%.

A metodologia do segmento foi o parâmetro que alcançou os resultados mais elevados, ou seja, os padrões de RBBB conseguiram distinguir a doença em estudo das outras doenças cardiovasculares.

Contudo, é de referir que algumas características também conseguiram obter muito bons resultados na distinção das patologias. No modelo BBBvsAr, as precisões mais altas foram obtidas com a ES_3 (77,56%) e a E_2 (77,55%). No que respeita à comparação do BBBvsCm os melhores resultados foram conseguidos na E_1 , ES_1 e Co_1 , com resultados a variar entre 89,51% e 89,70%. O modelo BBBvsHC obteve uma precisão máxima na característica ES_1 demonstrando um resultado de 78,90%. No BBBvsM quase todas as características obtiveram resultados que se encontravam entre 90,58% e 91,68%. As precisões mais altas para o BBBvsMH estão presentes no primeiro nível da decomposição de cada uma das características extraídas, com precisões a variar entre 90,84% e 90,90%. Os resultados menos significativos estão presentes na comparação BBBvsMI, com as precisões a variar entre 64,31% e 66,51%, demonstrando assim alguma dificuldade na distinção entre as duas patologias. Ao analisar a comparação BBBvsVHD, o melhor resultado foi obtido na característica E_2 com uma precisão de 82,00%.

No geral, o método de segmentos de 0,156 segundos apresentou os melhores resultados. As características que obtiveram os resultados mais satisfatórios foram as E_1 , E_2 e a ES_1 . As características que apresentaram os resultados menos significativos foram as Co_1 e Co_2 .

Há a salientar que os estudos levados a cabo por [10], [11], [13] e [14] utilizaram a mesma base de dados do presente estudo e apesar das métricas usadas terem sido diferentes, o presente estudo ultrapassou o estados da arte ao alcançar 100% de precisão.

Conclusões e Trabalho Futuro

5.1 Satisfação dos Objetivos

Os bloqueios dos ramos são doenças cardiovasculares que apesar de não serem muito preocupantes, no que diz respeito aos problemas que podem trazer para os doentes, são excelentes indicadores de patologias futuras e a sua identificação preventiva possibilita o antecipar do aparecimento de outras patologias muito mais perigosas para os doentes.

De forma a conseguir identificar esta doença, este trabalho usou ECGs, de uma base de dados pública. Com o auxílio da transformada de Wavelet, o presente estudo conseguiu utilizar outras características para além do padrão da doença, com o objetivo de possibilitar a identificação da patologia por outros meios. A utilização da CNN para classificar foi uma abordagem pioneira uma vez que este algoritmo é normalmente conhecido pelo seu uso em processamento de imagem.

De forma geral, o estudo apresentou resultados muito satisfatórios, demonstrando que é possível distinguir o BBB das outras doenças cardiovasculares, contudo é importante referir que existem alguns pontos a melhorar.

5.2 Trabalho Futuro

Numa perspetiva futura, de forma a melhorar o algoritmo desenvolvido neste trabalho, seria importante ter em conta os seguintes pontos chave:

- A utilização de um algoritmo que use múltiplas características que possibilitem uma melhor distinção da doenças por parte do algoritmo;
- Aumento do número de doentes com bloqueio do ramo esquerdo, para que seja possível realizar estudos que distingam entre as duas variantes de BBB;

- Aumento do número de amostras em algumas doenças, para a que seja possível a utilização de testes estatísticos mais robustos;
- Desenvolver uma interface gráfica, de forma que seja possível aplicar o algoritmo em ambientes clínicos.

Bibliografia

- [1] R. Drake. *Gray's anatomy for students*. Philadelphia, PA: Churchill Livingstone/Elsevier, 2015. ISBN: 9780702051333.
- [2] C. VanPutte. *Seeley's anatomy & physiology*. New York, NY: McGraw-Hill, 2014. ISBN: 0073403636.
- [3] M. Thaler. *The Only EKG Book You'll Ever Need, International Edition*. Lippincott Williams&Wilki, 2 de fev. de 2018. 384 pp. ISBN: 197510806X.
- [4] G. Wagner e D. Strauss. *Marriott's Practical Electrocardiography*. Lippincott Williams&Wilki, 1 de dez. de 2013. 552 pp. ISBN: 1451146256.
- [5] World Health Organization. *Hospital medical equipment*. https://www.who.int/medical_devices/priority/core_equipment/en/index2.html. Acedido no dia: 2020-10-09. 2017.
- [6] Standford Health Care. *EKG's Risks*. <https://stanfordhealthcare.org/medical-tests/e/ekg/risks.html>. Acedido no dia: 2020-10-09. 2017.
- [7] J. Hampton. *The ECG Made Easy*. Churchill Livingstone, 2013. ISBN: 978-0702046414.
- [8] Z. Goldberger e A. Shvilkin. *Goldberger's Clinical Electrocardiography*. Elsevier - Health Sciences Division, 12 de mai. de 2017. 288 pp. ISBN: 0323401694.
- [9] H. Huang, J. Liu, Q. Zhu, R. Wang e G. Hu. "Detection of inter-patient left and right bundle branch block heartbeats in ECG using ensemble classifiers". Em: *BioMedical Engineering OnLine* 13.1 (2014), p. 72. DOI: 10.1186/1475-925x-13-72.
- [10] M. Ali, J. Hartini e N. Nasrul. "Hybrid multilayered perceptron network for classification of bundle branch blocks". Em: *2012 International Conference on Biomedical Engineering (ICoBE)*. IEEE, 2012. DOI: 10.1109/icobe.2012.6178973.
- [11] M. Ali, J. Hartini, N. Nasrul e M. Som. "Classification of bundle branch blocks using multilayered perceptron network". Em: *2011 IEEE International Conference on Control System, Computing and Engineering*. IEEE, 2011. DOI: 10.1109/iccsce.2011.6190583.

- [12] P. Ranaware e R. Deshpande. "Detection of arrhythmia based on discrete wavelet transform using artificial neural network and support vector machine". Em: *2016 International Conference on Communication and Signal Processing (ICCSP)*. IEEE, 2016. DOI: 10.1109/iccsp.2016.7754470.
- [13] J. Yan, Y. Lu, Y. Xu, J. Liu e X. Wu. "INTELLIGENT DIAGNOSIS OF CARDIOVASCULAR DISEASES UTILIZING ECG SIGNALS". Em: *International Journal of Information Acquisition* 07.02 (2010), pp. 81–97. DOI: 10.1142/s0219878910002087.
- [14] R. Tripathy e S. Dandapat. "Multiresolution inter-sample and inter-lead eigen error features for classification of cardiac diseases". Em: *2016 Twenty Second National Conference on Communication (NCC)*. IEEE, 2016. DOI: 10.1109/ncc.2016.7561157.
- [15] R. Bousseljot, D. Kreiseler e A. Schnabel. *The PTB Diagnostic ECG Database*. 2004. DOI: 10.13026/C28C71.
- [16] R. Bousseljot, D. Kreiseler e A. Schnabel. "Nutzung der EKG-Signaldatenbank CARDIODAT der PTB über das Internet". Em: *Biomedizinische Technik/Biomedical Engineering* (2009), pp. 317–318. DOI: 10.1515/bmte.1995.40.s1.317.
- [17] D. Ballesteros, A. Gaona e L. Pedraza. "Discrete Wavelet Transform in Compression and Filtering of Biomedical Signals". Em: *Discrete Wavelet Transforms - Biomedical Applications*. InTech, 2011. DOI: 10.5772/19529.
- [18] C. Gopinathand e H. Guo. *Introduction to Wavelets and Wavelet Transforms*. Pearson Education (US), 14 de ago. de 1997. 288 pp. ISBN: 0134896009.
- [19] D. Sundararajan. *Discrete Wavelet Transform*. John Wiley & Sons, 3 de ago. de 2015. 344 pp.
- [20] J. Schmidhuber. "Deep learning in neural networks: An overview". Em: *Neural Networks* 61 (2015), pp. 85–117. DOI: 10.1016/j.neunet.2014.09.003.
- [21] Y. LeCun, Y. Bengio e G. Hinton. "Deep learning". Em: *Nature* 521.7553 (2015), pp. 436–444. DOI: 10.1038/nature14539.
- [22] MathWorks. *Convolutional Neural Network*. <https://www.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>. Acedido no dia: 2020-10-01.
- [23] R. Acharya, H. Fujita, S. Oh, Y. Hagiwara, J. Tan e M. Adam. "Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals". Em: *Information Sciences* 415-416 (2017), pp. 190–198. DOI: 10.1016/j.ins.2017.06.027.
- [24] S. Sanei, A. Constantinides e D. Jarchi. *Body Sensor Networking, Design and Algorithms*. WILEY, 13 de jul. de 2020. 416 pp. ISBN: 1119390028.
- [25] Matlab&Simulink. *Cross-Validation*. <https://www.mathworks.com/discovery/cross-validation.html>. Acedido no dia: 2020-10-02.

-
- [26] K. Murphy e F. Bach. *Machine Learning: A Probabilistic Perspective*. MIT Press Ltd, 24 de ago. de 2012. ISBN: 0262018020.

Resultados conseguidos nos contadores e na CNN

A.1 Resultados dos contadores para os vários níveis da Energia

Tabela A.1: Resultados obtidos nos contadores para a totalidade das derivações, nos 3 níveis da decomposição, na Energia (S = BBB contabilizado mais vezes, N = BBB contabilizado menos vezes).

Doença	Intervalo											
	total	>3,05e-07			<3,05e-07			> 1,55e-12 < 6,86e-05				
		total n=1	total n=2	total n=3	total	total n=1	total n=2	total n=3	total	total n=1	total n=2	total n=3
CM	N	N	N	N	S	S	S	S	N	N	S	S
Ar	N	N	N	N	S	S	S	S	N	N	S	S
HC	N	N	N	N	S	S	S	S	S	S	S	S
Mc	N	N	N	N	S	S	S	S	S	S	S	S
MI	N	N	N	N	S	S	S	S	N	S	S	S
MH	N	N	N	N	S	S	S	S	N	S	S	S
VHD	N	N	N	N	S	S	S	S	N	N	S	S

A.2 Resultados para os vários níveis dos contadores na Entropia

Tabela A.2: Resultados demonstrados pelos contadores para a totalidade das derivações, nos 3 níveis da decomposição, na Entropia (S = BBB contabilizado mais vezes, N = BBB contabilizado menos vezes).

Doença	Intervalo											
	>4,27e-06				<4,27e-06				> 0 < 8,82e-04			
	total	total n=1	total n=2	total n=3	total	total n=1	total n=2	total n=3	total	total n=1	total n=2	total n=3
CM	N	N	N	N	S	S	S	S	S	S	S	S
Ar	N	N	N	N	S	S	S	S	S	S	S	S
HC	N	N	N	N	S	S	S	S	S	S	S	S
Mc	N	N	N	N	S	S	S	S	S	N	N	S
MI	N	N	N	N	S	S	S	S	S	S	S	S
MH	N	N	N	N	S	S	S	S	N	S	S	S
VHD	N	N	N	N	S	S	S	S	S	N	S	S

A.3 Resultados dos contadores para os vários níveis da Coerência

Tabela A.3: Resultados adquiridos nos contadores para a totalidade das derivações, nos 3 níveis da decomposição, na Coerência (S = BBB contabilizado mais vezes, N = BBB contabilizado menos vezes).

Doença	Intervalo											
	>8,90e-17				<8,90e-17				> 1,64e-29 < 2,74e-14			
	total	total n=1	total n=2	total n=3	total	total n=1	total n=2	total n=3	total	total n=1	total n=2	total n=3
CM	N	N	N	N	S	S	S	S	N	N	S	S
Ar	N	N	N	N	S	S	S	S	N	N	S	S
HC	N	N	N	N	S	S	S	S	S	S	S	S
Mc	N	N	N	N	S	N	S	S	S	S	S	S
MI	N	N	N	N	S	S	S	S	S	S	S	S
MH	N	N	N	N	S	S	S	S	S	S	S	S
VHD	N	N	N	N	S	S	S	S	N	N	S	S