



CATÓLICA  
ESCOLA SUPERIOR DE BIOTECNOLOGIA

---

PORTO

DETEÇÃO DE ENFARTE DO  
MIOCÁRDIO ATRAVÉS DE REDES  
NEURONAIAS CONVOLUCIONAIS

por

Joana Emília Costa Sá

Março 2021





**CATÓLICA**  
**ESCOLA SUPERIOR DE BIOTECNOLOGIA**

---

PORTO

# DETEÇÃO DE ENFARTE DO MIOCÁRDIO ATRAVÉS DE REDES NEURONAIS CONVOLUCIONAIS

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

por

**Joana Emília Costa Sá**

Escola Superior de Biotecnologia, Universidade Católica Portuguesa

Orientador: Prof. Doutor Pedro Miguel de Luís Rodrigues

Março 2021



# Resumo

**Introdução:** As doenças cardiovasculares apresentam uma elevada taxa de mortalidade a nível mundial. O Eletrocardiograma (ECG) é o exame de primeira linha no que diz respeito ao diagnóstico deste tipo de patologias e conseqüentemente de extrema importância na correta e rápida interpretação para um prognóstico promissor. O Enfarte do Miocárdio (EM) é uma das alterações eletrocardiográficas que, detetadas atempadamente pode apresentar um impacto enorme a nível fisiológico e anatómico do próprio músculo cardíaco.

A necessidade existente de uma tomada de decisão rápida e acertada, levou ao desenvolvimento de algoritmos capazes de detetar patologias no sinal eletrocardiográfico.

**Metodologia:** Com o intuito de maximizar a capacidade discriminativa dos diferentes tipos de EM, foram extraídos padrões específicos do ECG para alimentar algoritmos de inteligência artificial. Por forma a tirar o melhor partido dos algoritmos de inteligência artificial foi realizado um pré-processamento de todo o sinal, seguido da seleção rigorosa de segmentos que apresentam a atividade patológica de cada doença. A seleção do segmento patológico para alimentar a Convolutional Neural Network (CNN) foi feita comparando os segmentos ao longo do tempo com as características modelo das sequências temporais do EM.

**Resultados:** Os modelos da CNN, utilizados no presente estudo, apresentam níveis de precisão superiores a 97%, 99,39%, 99,64%, 97,76% e 98,98% para o EM Anterior, Anterolateral, Inferior e Inferolateral, respetivamente. Os resultados discriminativos promissores provam que a etapa de seleção dos segmentos modelo proporcionaram uma excelente triagem entre sequências temporais patológicas e não patológicas, estando a CNN preparada para detetar essa atividade patológica associada a cada uma das modalidades para a qual foi treinada, sempre que, lhe seja apresentado um novo sinal de ECG como entrada

**Palavras-chave:** Eletrocardiograma; Enfarte do Miocárdio; coeficiente de correlação, Convolutional Neural Network; validação cruzada.



# Abstract

**Introduction:** Cardiovascular diseases have a high mortality rate worldwide. The Electrocardiogram is the first-line exam in what concerns the diagnosis of this type of pathologies and, consequently, with extreme importance in the correct and immediate interpretation for a promising prognosis. Myocardial infarction is one of the electrocardiographic changes that detected in a timely manner can have a huge impact at the physiological and anatomical level of the cardiac muscle itself.

The existing need for a fast and correct decision-making has led to the development of algorithms capable of detecting pathologies in the electrocardiographic signal.

**Methodology:** In order to maximize the discriminative capacity of the different types of myocardial infarction, specific patterns have been extracted from the ECG signals to feed artificial intelligence algorithms. In order to make the best use of the artificial intelligence algorithms, a pre-processing of the entire signal was performed followed by a rigorous selection of the segments that show pathological activity for each disease. The pathological segment selection for feeding the CNN was made by comparing the segments over time with time-series-sequency model's characteristic of myocardial infarction.

**Results:** The precision values of the models used in the present study, presented accuracy levels above 97%, 99.39%, 99.64%, 97.76% and 98.98% for the Anterior, Anterolateral, Inferior and Inferolateral, respectively. The promising discriminative results prove that the segment model selection stage allow to perform an excellent screening of the pathological sequencies from the non-pathological time-series sequences and the CNN model is ready for detecting pathological activity over time as a new ECG signal is presented to its entries.

**Keywords:** Electrocardiogram; Myocardial infarction; Correlation coefficient, Convolutional Neural Network; Crossed Validation.



# Agradecimentos

Com a conclusão da minha dissertação gostaria de deixar o meu agradecimento a todos aqueles que de certa forma contribuíram para o culminar desta etapa.

Primeiramente e de uma forma muito especial, ao Professor Pedro Rodrigues por todos os ensinamentos e por todo o suporte, dedicação, orientação e disponibilidade, que foram essenciais ao longo de todo o percurso.

Quero também deixar um enorme agradecimento ao Professor João Paulo Ferreira por toda a ajuda e apoio ao longo de todo o meu percurso académico na Escola Superior de Biotecnologia da Universidade Católica Portuguesa.

Quero deixar um agradecimento muito especial à minha amiga e colega de mestrado Inês Sousa, ao Pedro Ribeiro e à Daniela Paiva por todo o apoio e pelo companheirismo ao longo de todo o percurso.

Agradecer aos meus pais por permitirem que os meus objetivos sejam concretizados e por todo o carinho e dedicação que sempre foram capazes de me proporcionar.

Quero também agradecer à minha irmã Simone Sá pelo apoio e por ser o meu porto seguro sempre que precisei.

Finalmente, mas não menos importante agradecer a todos os meus amigos, em especial ao meu melhor amigo e namorado pela compreensão e apoio.

A todos, um sincero Muito Obrigada!



*“It always seems impossible until it’s done”*

Nelson Mandela



# Índice

<b>1. INTRODUÇÃO .....</b>	<b>1</b>
1.1. Motivação.....	1
1.2. Objetivo .....	1
1.3. Organização .....	2
<b>2. O CORAÇÃO ANATOMIA E FISILOGIA .....</b>	<b>3</b>
2.1. O coração .....	3
2.2. Anatomia e fisiologia.....	3
2.2.1. Anatomia do coração .....	3
2.2.2. Atividade elétrica cardíaca .....	4
2.3. Modos de detecção da atividade elétrica.....	5
2.3.1. Princípios básico da eletrocardiografia.....	5
2.3.2. Elétrodos e derivações .....	6
<b>3. DOENÇA CORONÁRIA.....</b>	<b>11</b>
3.1. Definição e fisiopatologia .....	11
3.2. Fatores de Risco .....	12
3.3. Prognóstico .....	12
<b>4. ENFARTE DO MIOCÁRDIO .....</b>	<b>13</b>
4.1. Definição .....	13
4.2. Alterações ao nível do ECG por isquemia, lesão ou enfarte .....	13
4.3. Alterações ao nível do ECG de acordo com a área lesada.....	14
4.4. Classificação clínica de Enfarte do Miocárdio.....	15

5.	TRABALHOS DESENVOLVIDOS NA ÁREA DO ESTUDO .....	17
6.	METODOLOGIA.....	19
6.1.	Base de dados .....	19
6.2.	Pré-processamento.....	21
6.3.	Extração de segmentos temporais patológicos modelo .....	21
6.4.	Coeficientes de correlação e análise estatística .....	23
6.5.	Deep Learning .....	26
6.5.1.	Convolutional Neural Network (CNN) .....	26
6.5.2.	Validação cruzada .....	28
6.5.3.	Aplicação do método .....	29
7.	RESULTADOS E DISCUSSÃO .....	31
7.1.	Resultados .....	31
7.2.	Discussão.....	33
8.	CONCLUSÕES E TRABALHOS FUTUROS.....	35
8.1.	Concretização dos objetivos.....	35
8.2.	Trabalhos futuros.....	35
	Bibliografia.....	37

# Índice de Figuras

Figura 2.1 Anatomia do coração [6].....	4
Figura 2.2 - Sistema de condução do estímulo elétrico [6].....	5
Figura 2.3 Despolarização do miocárdio e o traçado eletrocardiográfico [8].....	6
Figura 2.4 Sistema de Einthoven [11] .....	7
Figura 2.5 Sistema de Goldberger [11] .....	7
Figura 2.6 Sistema de Wilson [11] .....	7
Figura 2.7 - Sistema de Frank [13].....	8
Figura 2.8 ECG normal.....	9
Figura 3.1 (A) - Circulação coronária normal; (B) - Doença arterial coronária [14].....	11
Figura 3.2 Arteria coronária com aterosclerose [14].....	11
Figura 4.1 Três tipos de alterações causadas pela diminuição do suprimento de oxigénio no miocárdio: isquemia, lesão e enfarte [6].....	13
Figura 4.2 Tipos de alterações eletrocardiográficas de acordo com o tempo no qual o miocárdio se encontra sem suprimento de oxigénio.....	14
Figura 4.3 Concentração dos principais marcadores sanguíneos de lesão do miocárdio com e sem perfusão [14].....	15
Figura 6.1 Diagrama de fluxo do pré-processamento de sinal .....	21
Figura 6.2 Numeração de 1 a 12 de todas as derivações do ECG .....	22
Figura 6.3 Diagrama de fluxo da extração de segmentos temporais patológicos modelo de sinal	22
Figura 6.4 Tipos de EM de acordo com a área do miocárdio lesado [6].....	23

Figura 6.5 Diagrama de fluxo da avaliação percentual e análise estatística .....	24
Figura 6.6 Rede Neuronal Convolucional .....	27
Figura 6.7 Validação Cruzada.....	28
Figura 6.8 Diagrama da criação da matriz treino à validação cruzada.....	29
Figura 7.1 Número de padrões com diferenças significativas por grupo em estudo.....	31
Figura 7.2 Segmentos patológicos modelo em cada tipo de EM em estudo na derivação 11 .....	32
Figura 7.3 Percentagem de coeficientes de correlação por derivação e por EM .....	32

# Índice de Tabelas

Tabela 1 - Metodologia de trabalhos desenvolvidos na área do estudo .....	17
Tabela 2 - Número de ECGs por diagnóstico .....	20
Tabela 3 - Número de ECGs por EM.....	20
Tabela 4 - Derivações com diferenças eletrocardiográficas por cada tipo de enfarte .....	25
Tabela 5 - Tipos de camadas nas CNNs e respectivas saídas.....	27
Tabela 6 - Resultados finais da precisão .....	33



## Abreviaturas e Símbolos

BD	Base de Dados
CNN	<i>Convolutional Neural Network</i>
ECG	Eletrocardiograma
EM	Enfarte do Miocárdio
GC	Grupo de Controlo Saudável
NSTEMI	<i>Non ST-elevation myocardial infarction</i>
STEMI	<i>ST- elevation myocardial infarction</i>



# 1. INTRODUÇÃO

## 1.1. Motivação

Segundo a *World Health Organization* 31% da mortalidade no mundo provém de doenças cardiovasculares, sendo as mais prevalentes as arritmias, paragens cardiorespiratórias e a insuficiência cardíaca [1].

O exame de diagnóstico mais frequentemente realizado para deteção de doenças cardiovasculares é o Eletrocardiograma (ECG). A correta e rápida interpretação do ECG e consequentemente a tomada de decisões por parte do clínico, é de extrema importância no prognóstico promissor para o utente [2].

O estudo e processamento do sinal elétrico do coração ter-se-á tornado de extrema importância na área clínica, permitindo a caracterização das atividades fisiológicas, bem como a parametrização de mecanismos disfuncionais.

O Enfarte do Miocárdio (EM) é uma das alterações eletrocardiográficas que se detetadas atempadamente podem ter um impacto enorme para o doente.

Com o intuito de aumentar a fiabilidade na interpretação do ECG, bem como a diminuição de erros na tomada de decisões, cada vez mais têm sido desenvolvidos vários algoritmos de processamento de sinal para este fim.

## 1.2. Objetivo

Segundo a *European Society of Cardiology* o EM pode ser classificado de acordo com a área lesada. Deste modo e tendo em conta a diversidade de EMs existentes, para este estudo em concreto foram escolhidos 4 tipos diferentes: o anterior, o anterolateral, o inferior e o inferolateral [3].

O principal objetivo do presente estudo consistiu no desenvolvimento de um algoritmo capaz de identificar automaticamente eventos característicos dos 4 tipos de EM selecionados.

Ao objetivo principal estavam associados como objetivos secundários a análise dos parâmetros utilizados para discriminar os vários tipos de EM em estudo e além disso, a análise da capacidade da Redes Neurais Convolucionais para a classificação dos EMs selecionados.

Por forma a tirar partido da maior capacidade discriminativa de alterações eletrocardiográficas presentes em indivíduos com EM, foram selecionadas sequências temporais típicas modelo desta patologia para o treino de Redes Neurais Convolucionais. Saliente-se que, a extração de

sequências temporais patológicas modelo permite diminuir a dimensão de dados descartando determinados segmentos de sinal que não apresentam importância para o estudo, com é o caso do intervalo PQ.

### 1.3. Organização

O presente estudo está dividido em oito capítulos.

O primeiro capítulo correspondente à introdução, o qual apresenta uma abordagem à temática e esclarece a motivação e o objetivo deste trabalho.

O segundo capítulo, centra-se na descrição teórica da anatomia e fisiologia do coração, bem como do exame de primeira linha para avaliação do estado anatómico e fisiológico do mesmo, o ECG.

A doença coronária e o EM, são os temas apresentados nos capítulos três e quatro, respetivamente. Nestes capítulos são apresentadas todas as alterações existentes a nível cardíaco perante este tipo de situação patológica.

O capítulo cinco aborda essencialmente estudos e algoritmos já colocados em prática relativos à eletrocardiografia a par do EM.

O capítulo seis diz respeito à metodologia e faz uma descrição detalhada do pré-processamento do sinal, da extração dos segmentos patológicos modelo, da obtenção dos coeficientes de correlação e finalmente a apresentação das técnicas de *machine learning* utilizadas.

O capítulo sete apresenta os resultados e a discussão dos mesmos.

Finalmente, no capítulo oito são apresentadas as conclusões mais relevantes e futuras linhas de investigação.

## 2. O CORAÇÃO ANATOMIA E FISILOGIA

### 2.1. O coração

O coração é a base do funcionamento de todo o sistema cardiovascular e, conseqüentemente, é um dos órgãos mais importantes do corpo humano.

Com o intuito de estudar aprofundadamente este órgão, a eletrocardiografia surgiu num contexto de avanços tecnológicos. Em 1889, Waller demonstrou no Primeiro Congresso Internacional de Fisiologistas, que era possível o registo de potenciais elétricos cardíacos. Este avanço inicial levou a que vários investigadores tentassem obter um traçado eletrocardiográfico o mais próximo possível do real. Após vários estudos para determinar a frequência de funcionamento do equipamento e através de fórmulas matemáticas, em 1902 Willem Einthoven registou uma onda de corrente elétrica cardíaca usando um galvanómetro. A partir de então, o ECG é considerado uma imagem gráfica representativa das forças elétricas geradas no coração [4].

### 2.2. Anatomia e fisiologia

#### 2.2.1. Anatomia do coração

O coração é um órgão muscular que se encontra envolvido por um saco fibroso, que se denomina de pericárdio e que se localiza no tórax. A parede cardíaca, o miocárdio, é composta essencialmente por células musculares cardíacas que permitem a organização do coração em quatro partes fundamentais: duas aurículas e dois ventrículos. De forma a que ocorra a correta circulação sanguínea é necessária a presença de válvulas normofuncionantes e válvulas semilunares. As válvulas mitral e tricúspide são válvulas normofuncionantes e dividem as aurículas e os ventrículos. As válvulas aórtica e pulmonar são válvulas semilunares que permitem a correta saída do sangue do coração. Relativamente à circulação sanguínea é importante referir que consiste num processo cíclico dentro de um circuito fechado, em que após a contração cardíaca o sangue é expulso do coração seguindo o seu trajeto normal (Figura 2.1) [5].




Figura 2.1 Anatomia do coração [6]

### 2.2.2. Atividade elétrica cardíaca

O coração é considerado uma “bomba” dupla em que ocorre a contração, quer do lado direito quer do esquerdo, em simultâneo. Efetivamente, para que o bombeamento do sangue seja eficiente é necessária uma contração sincronizada das cavidades cardíacas, havendo uma contração inicial das aurículas e de seguida dos ventrículos [5] [7].

A contração do músculo cardíaco, bem como do músculo esquelético e outros músculos lisos é desencadeada pela despolarização da membrana plasmática, sendo que, este processo é denominado de potencial de ação [5].

Para que ocorra a contração do miocárdio é necessário um sistema de geração e condução do sinal elétrico, que é constituído pelo nó sinusal, pelas vias internodais auriculares, pelo nó auriculoventricular, pelo feixe de His e, por fim, pelas fibras de Purkinje (Figura 2.2) [5].




Figura 2.2 - Sistema de condução do estímulo elétrico [6]

A despolarização de cada uma das componentes acima referida não ocorre da mesma forma em todo o circuito, sendo a velocidade de condução a principal diferença entre as mesmas, permitindo deste modo, a formação do traçado eletrocardiográfico [7] [8].

## 2.3. Modos de detecção da atividade elétrica

### 2.3.1. Princípios básico da eletrocardiografia

Cada batimento do coração, contração mecânica, é precedido de um impulso elétrico. O ECG registra apenas o evento elétrico que constitui o estímulo para a contração mecânica. É um exame com muita utilidade por ser de baixo custo e por permitir a identificação das principais patologias cardíacas quando devidamente realizado e interpretado [8].

O potencial de ação estimula cada célula para que se contraia e os elétrodos detetam a soma dos potenciais de ação das células musculares das aurículas e dos ventrículos dando origem à onda P, ao complexo QRS e à onda T (Figura 2.3) [7] [8].




Figura 2.3 Despolarização do miocárdio e o traçado eletrocardiográfico [8]

### 2.3.2. Eléttodos e derivações

O ECG pode ser adquirido através da medição da diferença de potencial entre o eléttodo que se encontra posicionado num determinado ponto previamente definido e o eléttodo de referência (derivação unipolar) ou através da diferença de potencial entre dois eléttodos ambos posicionados de acordo com a literatura (derivação bipolar). As deflexões positivas e negativas estão relacionadas com o facto de a despolarização estar na direção do eléttodo ou na direção oposta, respetivamente [7][9].

Um ECG clínico típico ou *standard* corresponde, deste modo, a múltiplas localizações de registo nos membros e no tórax, denominadas de derivações (ou *leads*) do ECG, com o intuito de obter o máximo de informação sobre as diferentes paredes do miocárdio. A forma e a amplitude da onda P, do complexo QRS e da onda T varia de acordo com a derivação [9].

O sistema de derivações pode ser obtido de várias formas, sendo que, o principal sistema das derivações bipolares é o sistema de Einthoven, das derivações unipolares são o de Goldberger e o de Wilson [10].

O sistema de Einthoven constitui o principal sistema de montagem bipolar, ocorrendo a formação de derivações bipolares em cada eixo/lado do tão conhecido "Triângulo de Einthoven", das quais DI, DII e DIII (Figura 2.4) [7][10].

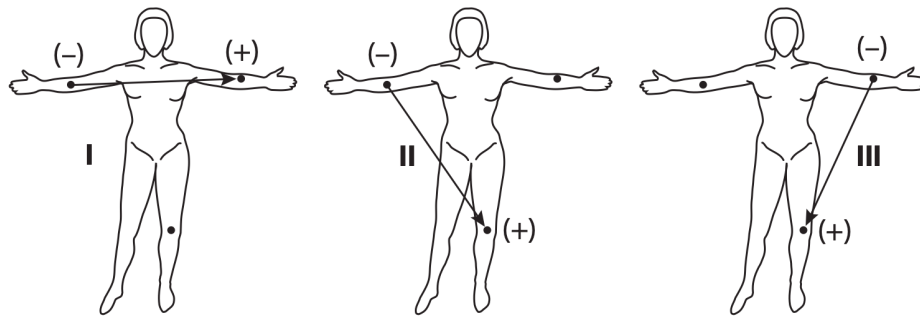


Figura 2.4 Sistema de Einthoven [11]

O sistema de Goldberger é considerado o sistema de derivações aumentadas em que ocorre a desconexão do elétrodo que se encontra mais próximo da derivação que se pretende medir, apresentando, conseqüentemente, uma amplitude maior que a alcançada nas derivações precordiais, sendo estas derivações unipolares definidas como aVF, aVR e aVL (Figura 2.5) [10].

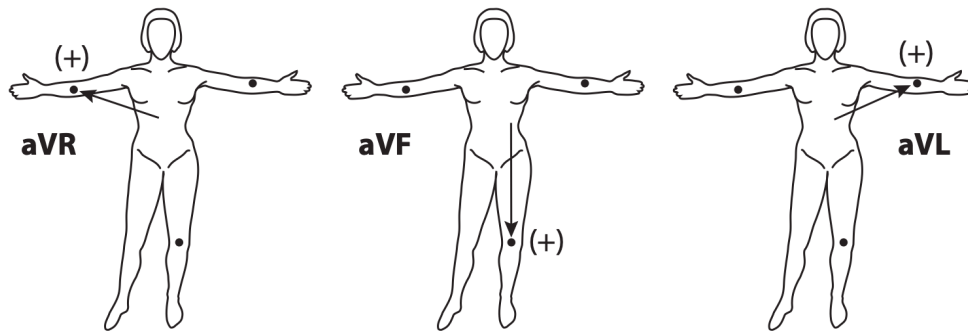


Figura 2.5 Sistema de Goldberger [11]

O sistema de Wilson é constituído por um conjunto de seis derivações unipolares (de V1 a V6) denominadas de derivações precordiais. Os elétrodos são colocados em sítios específicos pré-definidos como está representado na Figura 2.6 para a realização de um ECG *standard* [10].

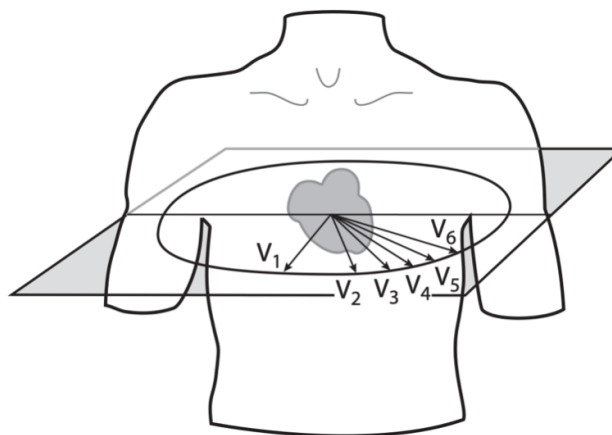


Figura 2.6 Sistema de Wilson [11]

Para finalizar é importante salientar a existência do sistema de Frank, o qual apresenta as derivações eletrocardiográficas ortogonais  $V_x$ ,  $V_y$  e  $V_z$ . Este tipo de derivações podem ser adquiridas monitorizando o indivíduo em sete posições distintas como é possível verificar na **Figura 2.7** [12] [13]




Figura 2.7 - Sistema de Frank [13]

### 2.3.3. ECG normal

O ECG é constituído por ondas, segmentos e intervalos, sendo que, cada um destes deve estar de acordo com uma série de parâmetros [6].

A onda P corresponde à primeira deflexão do ECG e representa a despolarização das células musculares auriculares, apresentando normalmente deflexão positiva em DI, DII, aVF e de V4 a V6, podendo nas restantes derivações ser bifásica. A sua amplitude não deverá exceder os 2,5 mm e a duração deve ser inferior a 11 ms [6].

O complexo QRS representa a despolarização das células musculares ventriculares, a sua duração não deve exceder os 10 ms [6].

A onda T é a representação do fim da repolarização dos ventrículos podendo, eventualmente, ser seguida de uma onda U. A onda T deve apresentar a mesma polarização do complexo QRS [6].

O segmento ST é representado pelo intervalo de tempo entre o fim do complexo QRS e o início da onda T e deve ser isoeletrico [6].

Dentro do grupo dos intervalos é possível constatar a existência de um intervalo PR, este deve ser medido desde o início da onda P até ao início do complexo QRS, não devendo ser inferior a 12 ms nem superior a 20 ms. O intervalo QRS deve encontrar-se entre os 8 e os 10 ms. Para finalizar, o intervalo QT corresponde ao tempo total necessário para que ocorra a despolarização e repolarização dos ventrículos. Este deve encontra-se entre os 350 e os 440 ms [6].

Um ECG só será considerado normal se apresentar todas as características acima referidas (Figura 2.8) [6].



Figura 2.8 ECG normal



## 3. DOENÇA CORONÁRIA

### 3.1. Definição e fisiopatologia

Doença coronária é o termo usado para descrever uma grande variedade de condições clínicas provocadas pelo desequilíbrio ao nível do suprimento de oxigénio no músculo cardíaco [14].

Na doença arterial coronária podem existir alterações ao nível de uma ou mais artérias coronárias, podendo provocar fluxo sanguíneo insuficiente denominando-se este fenómeno por isquemia. Este fenómeno poderá provocar uma lesão do músculo cardíaco na região afetada ou em situações de maior gravidade levar à morte ou necrose do tecido (Figura 3.1) [14] [15].

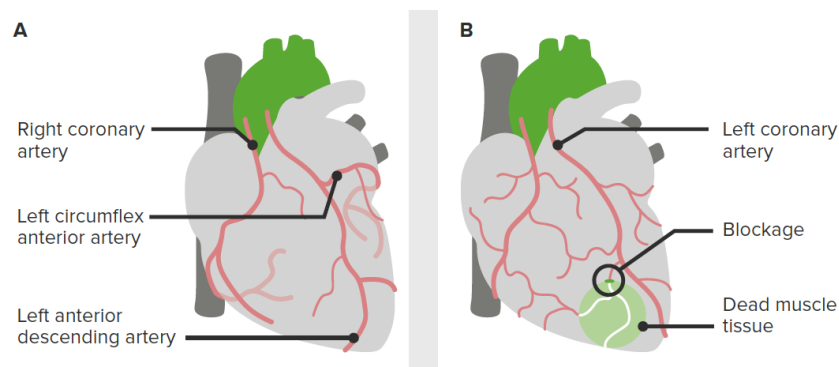


Figura 3.1 (A) - Circulação coronária normal; (B) - Doença arterial coronária [14]

O fator mais comum no aparecimento de doença isquémica das artérias coronárias é a aterosclerose consequência de uma série de condições cardiovasculares. Este tipo de patologia deve-se à presença de *stress* crónico do endotélio, levando à invasão de células inflamatórias com consequente adesão plaquetária. Além disso, poderá ocorrer a inflamação do próprio vaso proporcionando a proliferação das células musculares lisas. O *stress* crónico do endotélio bem como o depósito de gordura na artéria conduz à obstrução parcial ou total com consequente perfusão inadequada (Figura 3.2) [16].




Figura 3.2 Artéria coronária com aterosclerose [14]

## 3.2. Fatores de Risco

Existem dois tipos de fatores de risco, os que não dependem diretamente do indivíduo sendo considerados fixos, e ainda, os modificáveis que dependem diretamente do mesmo [17].

São considerados fatores de risco fixos a idade, o gênero e a história familiar. A dislipidemia, a hipertensão arterial, os hábitos tabágicos, a diabetes *mellitus*, a obesidade, o álcool, e ainda, a ausência de uma dieta saudável e de exercício físico são fatores de risco que dependem diretamente do indivíduo [17].

Segundo a *European Heart Network*, os três principais fatores que apresentam maior probabilidade de resultar em doença cardiovascular são a ausência de uma dieta saudável, a hipertensão arterial e a dislipidemia [17].

## 3.3. Prognóstico

O prognóstico da doença isquêmica depende essencialmente de três fatores fundamentais: a função do ventrículo esquerdo, a localização, a severidade da estenose da artéria coronária e ainda o número e consequente severidade dos fatores de risco do indivíduo em estudo [14].

A função do ventrículo esquerdo é de extrema importância, pois um fraco prognóstico passa pelo aumento da pressão deste e consequentemente um aumento de volume a ser ejetado, o que a médio prazo apresenta consequências nefastas ao nível da fração de ejeção [14].

No que diz respeito à localização e severidade da artéria estenosada é importante salientar que a estenose da artéria coronária descendente anterior trará o pior prognóstico possível a ser apresentado nesta vertente. Esta artéria irriga uma grande área do miocárdio e consequentemente maior será a área a sofrer isquemia [14].

É evidente que os fatores de risco são uma componente de extrema importância no que diz respeito à isquemia do miocárdio, tendo em conta que, quanto maior o número de fatores de risco apresentados, maior será o risco de desenvolvimento de aterosclerose e consequentemente maior o risco de uma perfusão inadequada [14].

## 4. ENFARTE DO MIOCÁRDIO

### 4.1. Definição

O termo EM refere-se à isquemia do músculo cardíaco em consequência da obstrução parcial ou total de uma ou mais artérias coronárias. A lesão do miocárdio resulta numa redução prolongada e aguda do fornecimento de sangue e conseqüentemente de oxigénio ao músculo cardíaco. O EM apresenta alterações irreversíveis no que diz respeito à morte de uma determinada área do mesmo [18].

Este evento está normalmente associado a alterações ao nível da concentração de enzimas específicas, como por exemplo a troponina, alterações ao nível eletrocardiográfico, sintomatologia típica ou ainda deteção de trombo via imagiologia médica [14] [18].

### 4.2. Alterações ao nível do ECG por isquemia, lesão ou enfarte

Os termos isquemia, lesão e enfarte são termos distintos, mas que apresentam em comum a diminuição do suprimento de oxigénio ao nível do músculo cardíaco (Figura 4.1) [6].

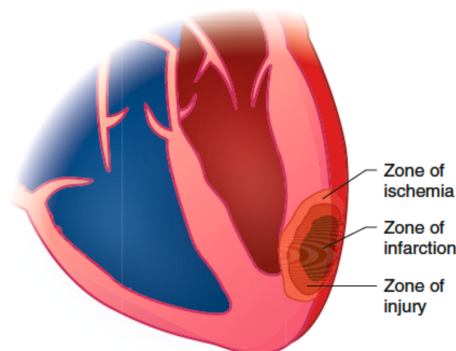


Figura 4.1 Três tipos de alterações causadas pela diminuição do suprimento de oxigénio no miocárdio: isquemia, lesão e enfarte [6]

A isquemia do miocárdio está associada à redução temporária e completamente reversível do fornecimento de sangue ao músculo. Esta será a primeira manifestação de que o fluxo coronário não se encontra em devidas condições [14] [19].

Ao nível eletrocardiográfico existem alterações na onda T, apresentando-se normalmente como positiva e assimétrica, tornando-se numa onda negativa e simétrica [6] [19] [20].

A lesão é o resultado de uma isquemia miocárdica prolongada e será reversível caso seja reestabelecido o fluxo sanguíneo, antes da morte do tecido. As principais alterações eletrocardiográficas correspondem a alterações ao nível do segmento ST, este poderá apresentar-se supradesnivelado ou infradesnivelado [6] [19] [20].

A morte irreversível do miocárdio devido à oclusão de uma ou mais artérias coronárias é definida como enfarte. Perante a morte do tecido existe a formação da onda Q patológica, onda com amplitude igual ou superior a um quarto da amplitude da onda R, nas derivações que representam a área lesada (Figura 4.2) [6] [19] [20].



Figura 4.2 Tipos de alterações eletrocardiográficas de acordo com o tempo no qual o miocárdio se encontra sem suprimento de oxigénio

### 4.3. Alterações ao nível do ECG de acordo com a área lesada

A isquemia, a lesão ou o enfarte podem ser avaliados e consequentemente localizados através do estudo cuidadoso de um ECG de 12 derivações [3] [7].

Existem quatro grandes grupos de EM associados à artéria coronária infetada: o anterior, o lateral, o inferior e o posterior [6].

O enfarte anterior resulta da oclusão da artéria coronária descendente anterior e por norma registam-se alterações nas derivações de V1 a V4. A obstrução da artéria circunflexa resulta num enfarte lateral em que as alterações poder-se-ão refletir nas derivações DI, aVL, V5 e V6. O enfarte inferior está associado a alterações ao nível da coronária direita provendo alterações nas derivações DII, DIII e aVF. Finalmente, o enfarte posterior está associado a alterações em espelho e dever-se-á realizar derivações adicionais para poder evidenciar-se a presença do mesmo [6].

## 4.4. Classificação clínica de Enfarte do Miocárdio

A classificação do EM é inevitável, para que seja possível a adoção imediata de estratégias de tratamento. Atualmente, existem dois grandes grupos para a avaliação do EM dos quais: *ST-elevation myocardial infarction* (STEMI) e o *non ST-elevation myocardial infarction* (NSTEMI) [3].

Perante a presença de sintomas sugestivos de síndrome coronária aguda por mais de 20 minutos é necessária a realização de um ECG [2].

Após a realização deste exame de primeira linha é importante avaliar a ocorrência de supradesnivelamento do segmento ST superior ou igual a 1 mm em 2 derivações contíguas ou verificar se eventualmente ocorreu o aparecimento de um bloqueio de ramo esquerdo de novo. Perante estas alterações eletrocardiográficas é possível a confirmação de um STEMI e, por conseguinte, não serão necessários quaisquer tipos de exame de diagnóstico para afirmação e confirmação de EM [18] [20].

No entanto, existem situações em que ocorre o infradesnivelamento do segmento ST e/ou a inversão da onda T ou em última instância o ECG ser normal. Nestes casos, é necessário recorrer-se a exames laboratoriais para avaliar a concentração de troponina e CK-MB pois estes apresentam-se como marcadores sanguíneos de lesão do miocárdio. Se eventualmente os resultados forem positivos, é possível concluir que e o individuo apresenta um NSTEMI, caso contrário, este apresenta apenas uma angina instável (Figura 4.3) [3] [14].

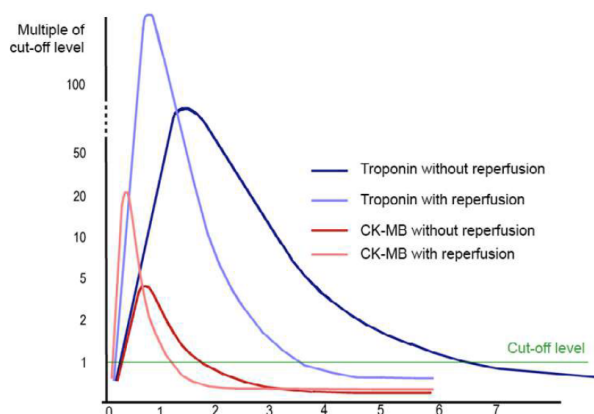


Figura 4.3 Concentração dos principais marcadores sanguíneos de lesão do miocárdio com e sem perfusão [14]



## 5. TRABALHOS DESENVOLVIDOS NA ÁREA DO ESTUDO

O desenvolvimento de algoritmos de análise automática de ECG tem vindo a ocorrer já há vários anos com o intuito de tornar consistente e fiável a sua interpretação e apoiar, deste modo, o diagnóstico médico.

De um modo geral, existem já vários métodos descritos e colocados em prática para a deteção de EM como é possível constatar na **Tabela 1**.

Tabela 1 - Metodologia de trabalhos desenvolvidos na área do estudo

#	Resultado	Base de Dados (BD)	Metodologia
[21]	Precisão: 80,60% Sensibilidade: 86,58% Especificidade: 64,71%	EM e GC	Foi criada uma aplicação de diagnóstico baseada na combinação do <i>Recursive Feature Eliminator</i> e dois algoritmos de <i>machine learning</i> , dos quais: o <i>K-nearest neighbors</i> e a artificial neural network com 10 <i>folds cross validation</i> , para a distinção entre ECGs com diagnóstico de EM ou normal.
[22]	Sensibilidade: 52% Especificidade: 97%	EM e outros diagnósticos	Método utilizado baseado numa simulação computacional da atividade elétrica cardíaca. Foram avaliados os seguintes critérios: duração da onda Q, amplitude da onda Q e R e o rácio entre ambas. Além disso, foi tida em conta a vetocardiografia para a realização do algoritmo <i>Cardíovise 2.0</i> .
[23]	Sensibilidade: 96,55% Especificidade: 95,24%	EM e outros diagnósticos	A periodicidade do traçado eletrocardiográfico admitiu com que este estudo fosse baseado na teoria do caos, permitindo a extração de porções de ECG que apresentam uma função discriminante.  O método utilizado foi o <i>Neuro-GA</i> com uma abordagem simplificada dos critérios anteriormente relatados. Os dados base foram gerados de acordo com uma solução de inteligência artificial.
[24]	Precisão: 91,89%	EM e outros diagnósticos	Primeiramente, foi realizado um tratamento do sinal, eliminando a oscilação da linha de base, o ruído e ainda, em tempo real, foi feita a deteção das ondas P, Q, R, S e T.

			O método utilizado para a avaliação de presença ou não de EM foi a transformada de <i>Wavelet</i> .
[25]	<p>Precisão: 98,80%</p> <p>Sensibilidade: 99,55%</p> <p>Especificidade: 96,27%</p>	EM e GC	<p>Numa primeira fase, todos os sinais de ECG foram submetidos a uma transformada de <i>Wavelet</i> discreta com 4 níveis de decomposição. Além desta, foram também estudadas mais 12 características não lineares do sinal, como por exemplo, as várias variantes da entropia.</p> <p>As características extraídas permitiram a alimentação de um algoritmo de <i>machine learning</i>, o <i>K-nearest neighbors</i>, apresentando-se como classificador usando um número bastante reduzido de recursos.</p> <p>O algoritmo criado permite a detecção de EM através a análise da derivação 11 (V5) e a localização do mesmo através da derivação 9 (V3).</p>
[26]	<p>Sensibilidade: 99,97%</p> <p>Especificidade: 99,9%</p>	EM e GC	<p>As características eletrocardiográficas tidas em conta para detecção do EM foram a amplitude da onda Q e T e os desvios do segmento ST.</p> <p>A extração dessas características do domínio do tempo foi possível através da transformada de <i>Wavelet</i>.</p> <p>A técnica de <i>machine learning</i> utilizada como classificador dos dados recolhidos, foi o <i>K-nearest neighbors</i>.</p> <p>O mesmo processo foi utilizado para a detecção da localização do EM.</p> <p>O algoritmo <i>Arif-Fayyaz</i> foi idealizado para diminuir o armazenamento de dados. Para tal, este apenas apresentou 7% dos dados de treino para detecção do EM e 30% dos dados de treino para a localização. Neste caso, existe uma ligeira queda nos valores de sensibilidade e especificidade, 97% e 99,6% respetivamente.</p>

Atualmente, alguns dos trabalhos desenvolvidos na área em estudo já apresentam níveis de precisão, sensibilidade e especificidade bastante elevados. Além disso, existem várias formas de classificação do sinal de ECG e conseqüentemente de detecção ou não de EM. No entanto, são vários os estudos que não apresentação resultados relativamente à localização da patologia em questão, sendo algo de extrema importância para a avaliação da extensão do EM e conseqüentemente dos danos causados no miocárdio.

## 6. METODOLOGIA

A metodologia deste estudo foi desenhada de forma a criar um sistema capaz de detetar a atividade específica de cada patologia cardíaca, registada no sinal eletrocardiográfico.

Com o intuito de maximizar a capacidade discriminativa dos vários de tipo de EM, foram extraídas sequências temporais patológicas modelo para alimentar algoritmos de inteligência artificial. Deste modo, a metodologia desenvolvida no presente estudo foi dividida em quatro fases principais: pré-processamento, extração das sequências temporais patológicas modelo, avaliação dos coeficientes de correlação e aplicação de algoritmos de inteligência artificial.

### 6.1. Base de dados

O presente trabalho foi realizado em ambiente MATLAB®.

A *PTB Diagnostic ECG Database*, BD a qual publica sinais de ECG com patologias cardíacas, foi a utilizada para a realização deste estudo. A BD tem as seguintes especificidades:

- Canais de entrada: 16 (14 para o ECG, 1 para a frequência respiratória e 1 para a linha de tensão);
- Tensão de entrada:  $\pm 16$  mV;
- Largura de banda: 0 – 1 kHz;
- Tensão máxima de ruído: 10  $\mu$ V;
- Resistência da pele: online;
- Nível de ruído: registo durante a recolha do sinal.

O número de registos desta BD é de 549, cada um dos quais apresenta as 12 derivações do ECG *standard* (DI, DII, DIII, aVF, aVR, aVL, V1, V2, V3, V4, V5, V6) e ainda 3 derivações adicionais correspondentes aos eixos ortogonais ( $V_x$ ,  $V_y$  e  $V_z$ ) [27].

Cada um dos registos apresenta também uma frequência de amostragem de 1000 Hz, 16 bits de resolução para um intervalo de  $\pm 16,384$  mV e ainda 10 segundos de tempo de recolha [27].

Da BD *PTB Diagnostic ECG Database* foram seleccionados 511 ECGs e a distribuição dos mesmos por doença apresentam-se descritos na **Tabela 2** [27].

Tabela 2 - Número de ECGs por diagnóstico

Diagnóstico	Número de ECGs
Bloqueios de Ramo	17
Cardiomiopatias	18
Miocardite	4
Hipertrofia do miocárdio	5
Doenças valvulares	5
Arritmias	16
EM	367
Grupo de controlo saudável (GC)	79

Dentro do grupo com diagnóstico de EM é possível constatar a presença de um diagnóstico adicional, permitindo assim a criação de subgrupos, como é possível verificar na **Tabela 3**.

Tabela 3 - Número de ECGs por EM

Diagnóstico adicional	Número de ECGs
EM inferior	94
EM inferolateral	57
EM infero-anterior	2
EM inferoposterior	4
EM infero-postero-lateral	20
EM anterior	53
EM anterolateral	45
EM anteroseptal	78
EM antero-septo-lateral	2
EM lateral	3
EM posterior	4
EM posterolateral	5

Para o presente estudo foram tidas em conta 446 amostras de ECG de pacientes diagnosticados como EM e como não patológicos (GC).

## 6.2. Pré-processamento

Após carregar os dados em MATLAB® foram criadas duas funções principais:

- *Myocardialinfarction*: ECGs com diagnóstico de EM;
- *Completedatabase*: ECGs com EM e o GC.

Todos os sinais foram sujeitos a um pré-processamento que correspondeu à sua normalização como é possível constatar na **Figura 6.1**.




Figura 6.1 Diagrama de fluxo do pré-processamento de sinal

A normalização, representada através da equação seguinte (1), apresenta como principal objetivo a tentativa de diminuição das diferenças energéticas entre sinais de diferentes indivíduos, onde  $N$  é o tamanho do sinal, ou seja, 10000 amostras ( $10s \times 1000Hz$ ) [28].

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

## 6.3. Extração de segmentos temporais patológicos modelo

Os quatro tipos de EM selecionados para o estudo foram o EM Anterior, o EM Anterolateral, o EM Inferior e o EM Inferolateral e de cada um destes subgrupos, de um determinado indivíduo, foram selecionadas 20 amostras de sinal de ECG aleatoriamente, para a seleção das sequências temporais patológicas modelo em todas as derivações.

Para facilmente identificar as derivações foram utilizados números de 1 a 12 como é possível observar na **Figura 6.2**.



Figura 6.2 Numeração de 1 a 12 de todas as derivações do ECG

Na literatura encontram-se descritas as alterações que ocorrem ao nível eletrocardiográfico, para que seja possível a realização de um determinado diagnóstico. O EM apresenta alterações eletrocardiográficas que podem variar ao longo do tempo, de acordo com o estado da lesão do músculo cardíaco (Figura 6.3) [9] [6].

Os sinais de ECG típicos de EM devem apresentar pelo menos uma das seguintes alterações:

- Onda T invertida [9] [6];
- Infra ou supradesnivelamento do segmento ST [9] [6];
- Ondas Q patológicas [9] [6].

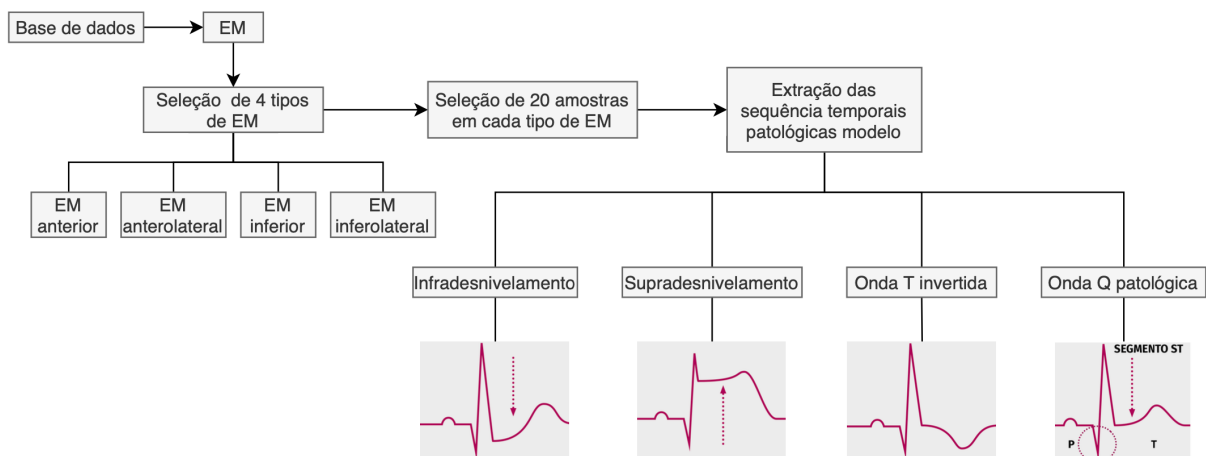


Figura 6.3 Diagrama de fluxo da extração de segmentos temporais patológicos modelo de sinal

De acordo com a área lesada, o ECG irá apresentar alterações nas respectivas derivações (Figura 6.4). Deste modo, como é possível constatar na Fig. 6.4, o EM anterior tende a apresentar as suas principais alterações ao nível das derivações V1, V2, V3 e V4, o EM anterolateral nas derivações DI, aVL e de V1 a V6, o EM inferior por sua vez apresenta as suas principais alterações nas derivações DII, DIII e aVF, ao passo que, o EM inferolateral apresenta alterações nas mesmas derivações do inferior acrescentando o DI, o aVL, o V5 e o V6 [6].



Figura 6.4 Tipos de EM de acordo com a área do miocárdio lesado [6]

## 6.4. Coeficientes de correlação e análise estatística

Como descrito na literatura, o coeficiente de correlação, representado através da equação 2, permite a medição do grau de proximidade entre duas grandezas, neste caso em concreto, o coeficiente de correlação foi calculado entre a sequência temporal patológica modelo selecionada à partida e as restantes amostras da *completedatabase* [29].

$$\rho_{xy} = \frac{\widehat{r}_{xy}(0) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2)$$

Para a obtenção de todos os valores dos coeficientes de correlação, foi necessário proceder previamente ao janelamento do sinal. De acordo com cada tipo de EM foram criadas janelas com os seguintes intervalos de tempo:

- EM anterior: 301 ms;
- EM anterolateral: 355 ms;
- EM inferior: 308 ms;
- EM inferolateral: 292 ms.

O tempo selecionado por janela depende do tamanho dos modelos patológicos de sinal previamente selecionados para o processo.

De acordo com a literatura o traçado eletrocardiográfico pode sofrer variabilidade do intervalo de tempo das suas ondas e segmentos de indivíduo para indivíduo, ainda que dentro dos limites da normalidade, justificando o facto das janelas anteriormente descritas não apresentarem o mesmo intervalo de tempo [6].

Aos coeficientes de correlação foram atribuídos níveis, permitindo deste modo, uma análise estatística bem como um estudo percentual.

Neste estudo foram tidos em conta os coeficientes de correlação superiores ou iguais a 0,8 para garantir uma maior fiabilidade dos dados. Além disso, foram atribuídos níveis de 1 até 20 em intervalos de 0,01 aos coeficientes de correlação para que os dados fossem interpretados facilmente.

Os coeficientes de correlação estavam organizados por matrizes que por sua vez estavam organizadas por EM em estudo, por derivação e por sequência temporal patológica modelo. A avaliação percentual destas matrizes permitiu com que fosse possível o cálculo da percentagem de sinal que apresentasse níveis de correlação superiores ou iguais a 0,8 em todos os ECGs da *completedatabase*.

A realização dos testes estatísticos apresentava como principal objetivo a constatação da existência ou não de diferenças significativas, ou seja, averiguar o que poderia ser típico da doença do que não o era, entre as 20 sequências temporais patológicas modelo recolhidas previamente do EM em estudo e as restantes amostras da *completedatabase*. A função ANOVA foi a utilizada para este processo, com intervalo de confiança de 95% (Figura 6.5).

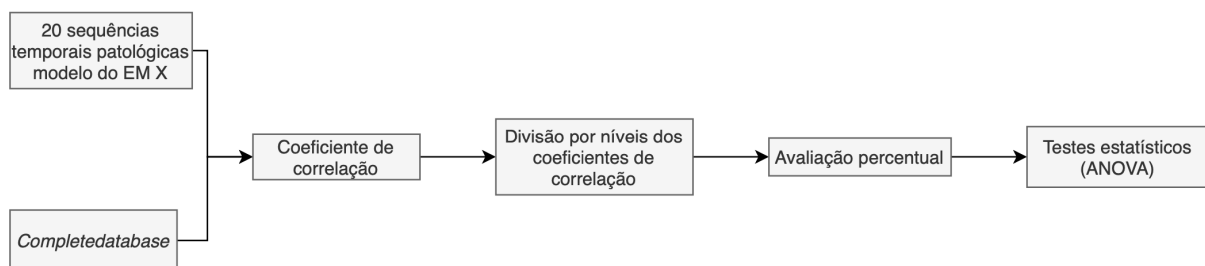


Figura 6.5 Diagrama de fluxo da avaliação percentual e análise estatística

O estudo percentual permitiu obter a percentagem do número de derivações com diferenças significativas por sequência temporal patológica modelo entre o EM em estudo e os restantes ECGs da *completedatabase*. Para esta análise não foram tidas em conta todas as derivações do ECG, apenas aquelas que poderiam apresentar diferenças segundo a literatura, como é possível verificar na Tabela 4.

Tabela 4 - Derivações com diferenças eletrocardiográficas por cada tipo de enfarte

EM Inferior	Derivação com diferenças eletrocardiográficas
EM Inferior vs EM Anterior	2,3,6,7,8,9,10
EM Inferior vs EM Anterolateral	1,2,3,5,6,7,8,9,10,11,12
EM Inferior vs EM Inferolateral	1,5,11,12
EM Inferior vs GC	2,3,6
EM Inferolateral	Derivação com diferenças eletrocardiográficas
EM Inferolateral vs EM Anterior	1,2,3,5,6,7,8,9,10,11,12
EM Inferolateral vs EM Anterolateral	2,3,6,7,8,9,10
EM Inferolateral vs EM Inferior	1,5,11,12
EM Inferolateral vs GC	1,2,3,5,6,11,12
Enfarte Anterior	Derivação com diferenças eletrocardiográficas
EM Anterior vs EM Inferior	2,3,6,7,8,9,10
EM Anterior vs EM Inferolateral	1,2,3,5,6,7,8,9,10,11,12
EM Anterior vs EM Anterolateral	1,5,11,12
EM Anterior vs GC	7,8,9,10
Enfarte Anterolateral	Derivação com diferenças eletrocardiográficas
EM Anterolateral vs EM Inferior	1,2,3,5,6,7,8,9,10,11,12
EM Anterolateral vs EM Inferolateral	2,3,6,7,8,9,10
EM Anterolateral vs EM Anterior	1,5,11,12
EM Anterolateral vs GC	1,5,7,8,9,10,11,12

Foram selecionadas as 4 melhores sequências temporais patológicas modelo de sinal, uma para cada tipo de EM em estudo, as quais apresentavam as seguintes características:

- Pelo menos 50% das derivações com diferenças eletrocardiográficas, representadas na **Tabela 4**, com diferenças significativas;
- Maior frequência na distinção entre os vários EM em estudo.

A seleção da melhor derivação passou pela realização dos coeficientes de correlação entre a melhor sequência temporal patológica modelo de sinal de cada tipo de EM e os restantes ECGs do mesmo tipo de EM, sendo escolhida aquela que apresentou mais níveis de correlação superiores a 0,8 de uma forma geral. Permitindo, deste modo, a utilização de apenas 1 derivação específica, a derivação 11 correspondente ao V5 num ECG *standard*, nos processos seguintes do presente estudo, como é o caso da alimentação dos algoritmos de inteligência artificial.

## 6.5. *Deep Learning*

As técnicas de *machine learning* apresentam como um dos seus principais métodos a *deep learning*. Baseando-se em métodos de redes neuronais artificiais, a *deep learning* possui como principal objetivo o reconhecimento de determinados padrões do quotidiano [30] [31].

As redes neuronais artificiais pretendem simular um cérebro humano e tal como este é necessário um processo de aprendizagem para adquirir conhecimento. Para tal, este tipo de processo é caracterizado pela existência de várias camadas de processamento não linear, com o objetivo de aprender determinados padrões hierárquicos de dados. A *deep learning* apresenta três diferentes formas de aprendizagem: a não supervisionada, a semi-supervisionada e a supervisionada. A aprendizagem supervisionada foi a escolhida para o presente estudo [32] [33].

A aprendizagem neste tipo de *machine learning* passa pela criação de uma matriz de treino, na qual estão incluídos todos os ECGs pertencentes à *completedatabase*. Associado a esta matriz de treino está um vetor target que funciona como a sua resposta desejada.

### 6.5.1. *Convolutional Neural Network (CNN)*

A CNN é uma das vertentes do *deep learning* que aprende um conjunto de dados sem a necessidade de extração manual de recursos [34].

As CNNs normalmente encontram-se associadas a reconhecimento de padrões em imagens, no entanto, também apresentam uma elevada eficácia na classificação de dados nomeadamente dados de sinal como é o caso deste estudo [34].

Sendo o processo de classificação dos dados pela CNN um algoritmo relacionado com um tipo de aprendizagem profunda, este só é possível na presença dos *layers* ou camadas. As CNNs podem exibir dezenas e até mesmo centenas de *layers* [34] [35].

Os *layers* podem apresentar três distintas posições das quais: os *input layers*, os *hidden layers* e ainda os *output layers*. Os dados que o investigador pretende analisar posicionam-se nos *input layers*. A alteração de dados por parte da CNN com o objetivo de aprendizagem de características específicas ocorre ao nível dos *hidden layers*. Finalmente, na última posição encontram-se os chamados *output layers*, resultado da aprendizagem dos dois *layers* anteriores permitindo a classificação dos dados [34] [35].

A aprendizagem dos dados ao longo dos três *layers* referidos anteriormente apenas é conseguido através de operações específicas, que promovem a alteração dos dados com o principal objetivo de os aprender. As três operações mais comuns são: a *convolution*, a *rectified linear unit* e a *pooling* [35].

A *convolution* através da aplicação de uma série de filtros convolucionais permite a criação de um novo conjunto de valores relativamente ao sinal introduzido. O mapeamento dos valores negativos para zero

mantendo os valores positivos ocorre ao nível da *rectified linear unit*, permitindo um treino mais rápido e eficaz. A *pooling* permite com que haja uma simplificação de dados consequente da diminuição do número de amostras através da redução do número de parâmetros de aprendizagem [35].

Depois da aprendizagem dos dados a CNN passa para a fase da classificação. A camada que permite a classificação dos dados é denominada de *fully connected layer*, nesta existe um vetor de saída, com uma dimensão  $y$  e onde  $y$  é número de classes que podem ser classificadas. Neste estudo, concretamente, apenas existem duas classes, ou tem doença ou não (Figura 6.6) [35].

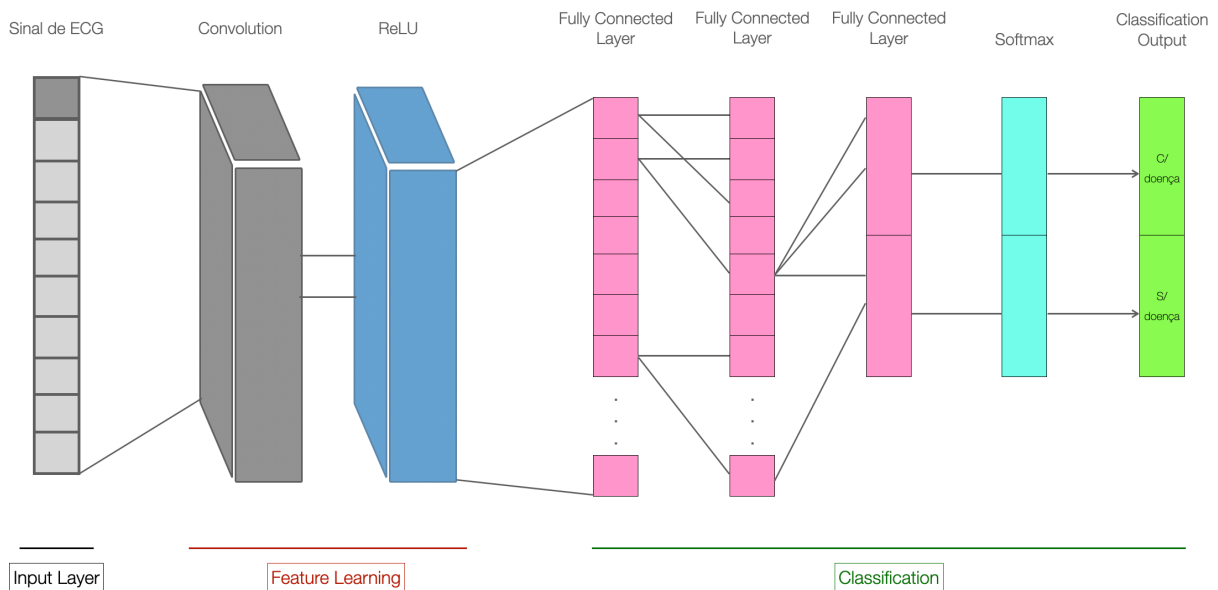


Figura 6.6 Rede Neuronal Convolucional

No presente estudo, o esquema utilizado nas CNNs está representado da Figura 6.6, sendo estas constituídas por 8 *layers* cada como é possível verificar através da Tabela 5.

Tabela 5 - Tipos de camadas nas CNNs e respetivas saídas

	EM Anterior	EM Anterolateral	EM Inferior	EM Inferolateral
Tipo de camada	Saída	Saída	Saída	Saída
ImageInputLayer	1,301,1	1,355,1	1,308,1	1,292,1
Convolution2DLayer	1,300,16	1,354,16	1,307,16	1,291,16
ReLULayer	1,300,16	1,354,16	1,307,16	1,291,16
FullyConnectedLayer	384			
FullyConnectedLayer	384			
FullyConnectedLayer	2			
SoftmaxLayer	2			
ClassificationOutputLayer	2			

### 6.5.2. Validação cruzada

A validação cruzada é considerada uma técnica de avaliação do desempenho de algoritmos de *machine learning*, permitindo a obtenção de previsões de novos dados que ainda não foram treinados e/ou aprendidos [36].

Esta técnica divide os dados aleatoriamente em dois grandes grupos, um de treino e outro de teste. A aleatoriedade deste sistema permite com que o grupo de teste nunca seja o mesmo, sendo que, o erro médio da validação cruzada é considerado um indicador da *performance*. Além disso, é possível o cálculo da precisão do modelo permitindo a generalização do modelo para dados futuros [36].

A validação cruzada apresenta várias técnicas para divisão dos dados de várias formas diferentes, em que o principal objetivo passa pela escolha do melhor algoritmo para o modelo. Várias são as técnicas disponíveis para a divisão dos dados, no entanto, para este estudo a utilizada foi o *K-fold*. O *K-fold* permite a divisão dos dados em K grupos aleatórios com um tamanho aproximadamente igual. Neste caso, um desses grupos permite a validação do modelo e este processo será repetido y vezes com alteração do grupo que valida o mesmo (Figura 6.7) [36].

30 *folds* foram o número de rondas pelos quais os dados estiveram sujeitos na presente dissertação. Este número elevado de *folds* apresentou como principal objetivo a diminuição do impacto de uma ronda com um resultado de precisão não tão favorável [36].

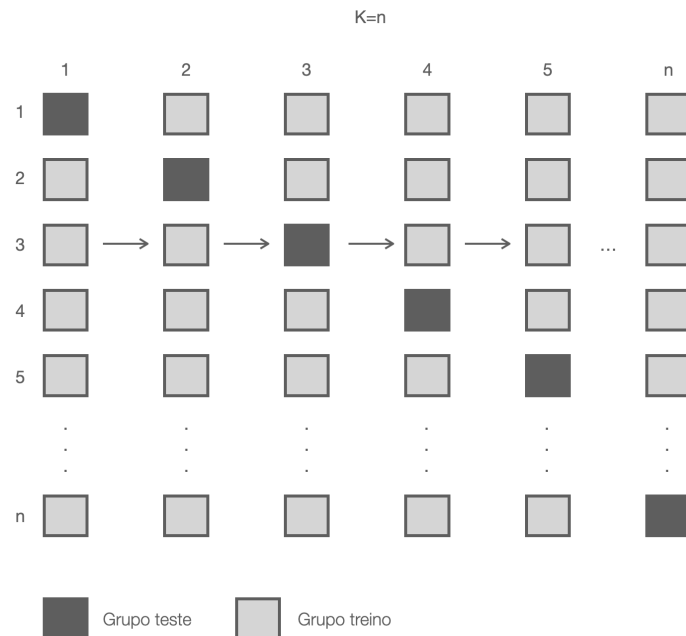


Figura 6.7 Validação Cruzada

### 6.5.3. Aplicação do método

A seleção dos segmentos patológicos foi realizada com o intuito de servirem de modelo para criação de um sistema capaz de os identificar como típicos de cada uma das modalidades da doença. Ou seja, o sistema ficará capacitado de os identificar ao longo de uma análise temporal do sinal de ECG. Portanto, foi tida em conta 1 derivação específica como entrada-saída da CNN, sendo considerada a melhor derivação aquela que apresentou mais frequentemente níveis de correlação superiores a 0,8 entre o melhor segmento modelo típico de cada EM e os restantes ECGs do mesmo tipo.

Desta forma, o processo foi realizado em duas partes:

- A todos os segmentos de sinal em que os coeficientes de correlação entre a melhor sequência temporal patológica de um EM em estudo e os restantes sinais do mesmo tipo de EM que fossem superiores ou iguais a 0,8, foi-lhes associado o valor de target 1, os restantes foram automaticamente eliminados;
- Os restantes segmentos da *completedatabase* foram selecionados e associados a um target de 0.

De forma a validar o método de seleção de padrões, ou seja, os segmentos temporais típicos para cada uma das modalidades da doença, respetivamente, os pares de entrada e saída selecionados alimentaram as CNNs num processo classificativo de validação cruzada de 30 *fold* (Figura 6.8).




Figura 6.8 Diagrama da criação da matriz treino à validação cruzada



## 7. RESULTADOS E DISCUSSÃO

### 7.1. Resultados

A avaliação dos coeficientes de correlação por EM permitiu concluir a existência de diferenças significativas entre as 20 sequências temporais patológicas modelo de sinal previamente selecionadas e as restantes amostras da BD tida em conta para o presente estudo, como é possível averiguar na **Figura 7.1**.

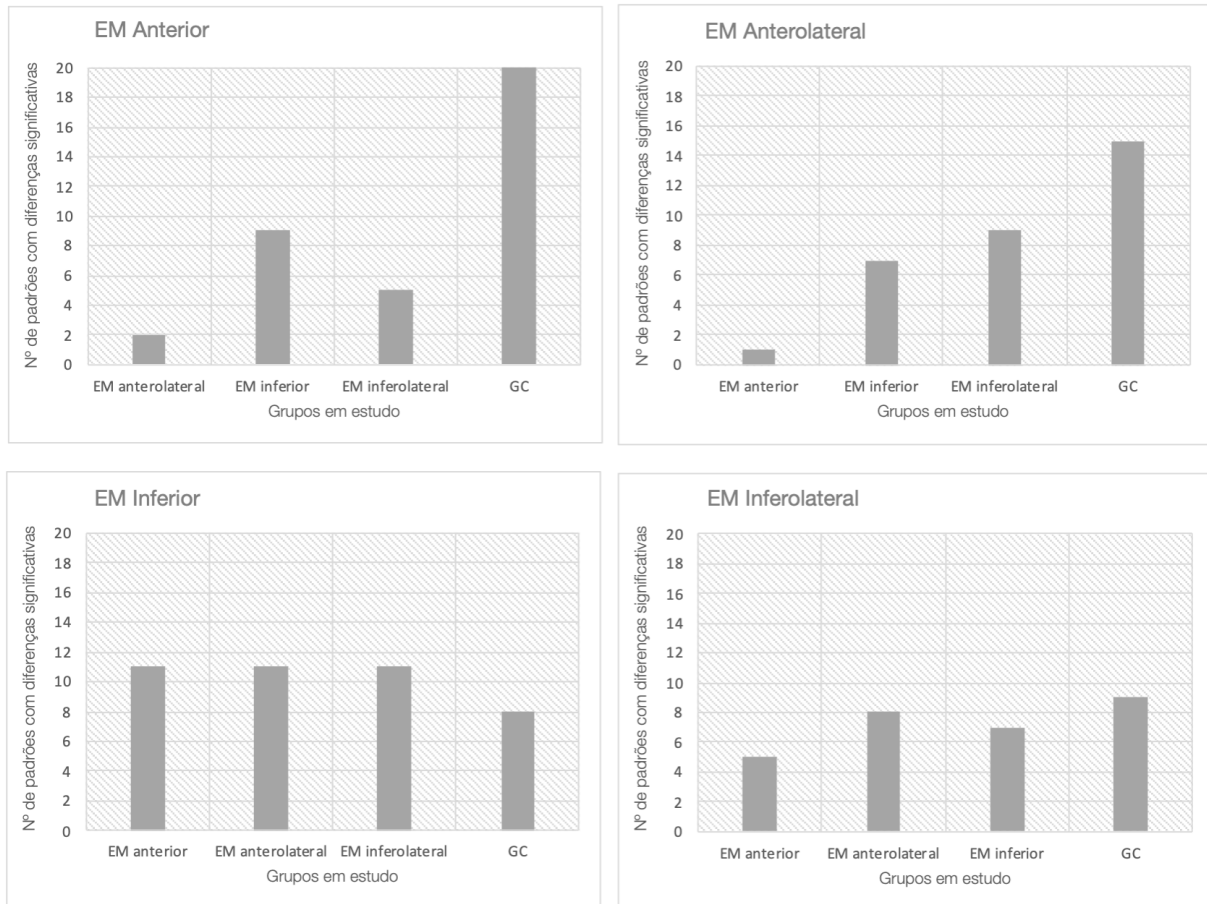


Figura 7.1 Número de padrões com diferenças significativas por grupo em estudo

Da BD com 446 ECGs foram escolhidos os 4 melhores segmentos patológicos modelo na derivação 11 de cada tipo de EM como é possível observar na **Figura 7.2**.

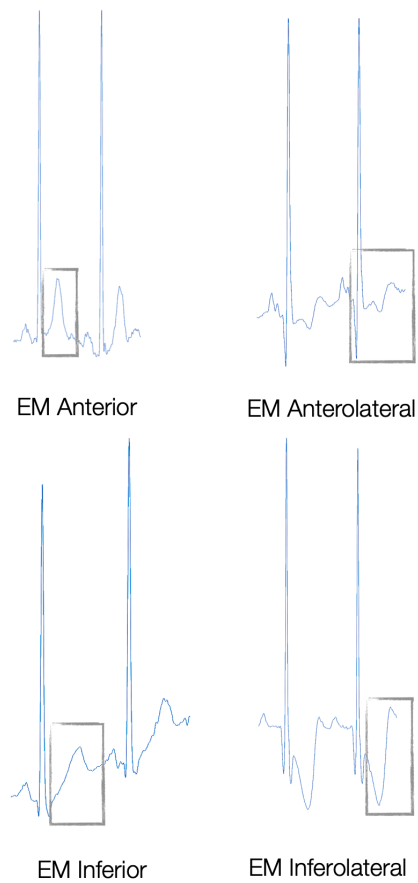


Figura 7.2 Segmentos patológicos modelo em cada tipo de EM em estudo na derivação 11

Como é possível constatar na Figura 7.3 a melhor derivação de um modo geral foi a 11, correspondendo ao V5 num ECG *standard*.

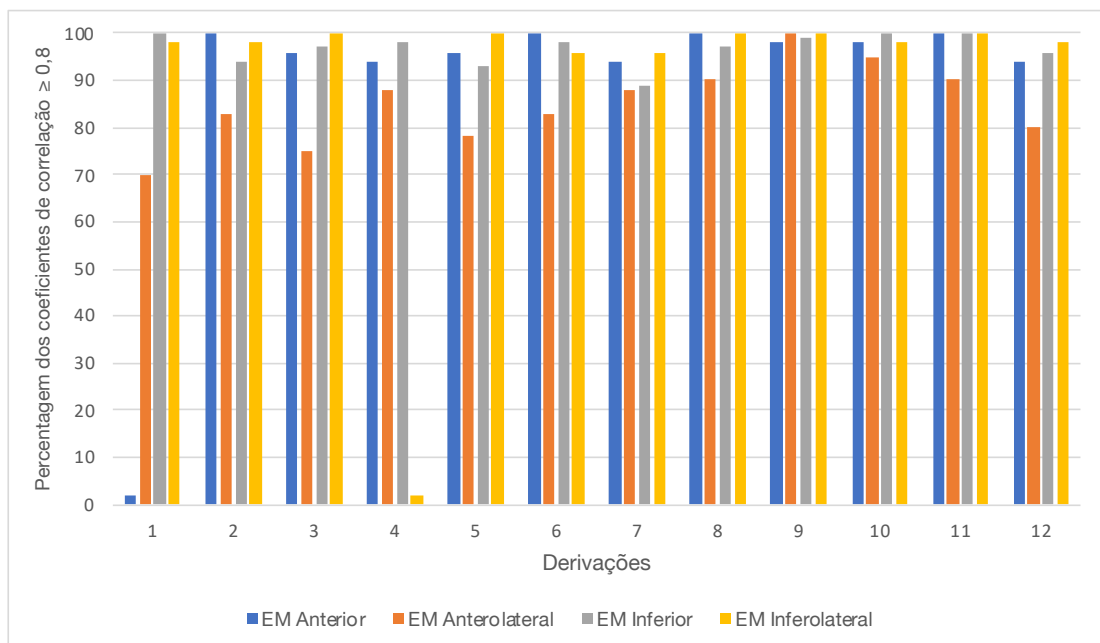


Figura 7.3 Percentagem de coeficientes de correlação por derivação e por EM

A Tabela 6 apresenta os resultados finais da precisão da validação cruzada das CNNs.

Tabela 6 - Resultados finais da precisão

Tipos de EM	Precisão (%)
EM Anterior	99,39
EM Anterolateral	99,64
EM Inferior	97,76
EM Inferolateral	98,98

## 7.2. Discussão

A avaliação dos coeficientes de correlação permitiu constatar que todos os EMs em estudo apresentaram pelo menos uma sequência temporal patológica modelo com diferenças significativas. É no EM anterolateral que se verifica um menor número de sequências temporais patológicas com diferenças significativas em relação ao EM anterior, podendo ser justificado pela proximidade das paredes do miocárdio e conseqüentemente alterações ao nível do ECG que embora não sejam consideradas patológicas podem apresentar ligeiras alterações pouco ou nada visíveis ao olho humano. Já os melhores resultados encontrados foram no GC em todos os tipos de EM em estudo, a inexistência de patologia é resultado de um traçado eletrocardiográfico mais coerente e uniforme.

A escolha dos melhores segmentos patológicos modelo permitiu averiguar a melhor derivação. A derivação 11, correspondendo ao V5 na monitorização do ECG *standard* foi considerada a melhor derivação, pois, de um modo geral, foi a que apresentou uma percentagem mais elevada de coeficientes de correlação superiores a 0,8. O V5, na prática clínica, é considerado uma derivação mais estável devido à sua posição no tórax numa monitorização *standard*, apresentando menos artefactos quer de trémulo muscular, quer da respiração, quer de movimentos aleatórios.

Os valores de precisão dos segmentos patológicos seleccionados por validação cruzada foram bastantes promissores, apresentado em todos os EMs valores de precisão superiores a 97%, dos quais: 99,39%, 99,64%, 97,76% e 98,98% para o EM Anterior, Anterolateral, Inferior e Inferolateral, respetivamente. Desta forma, ocorre a validação dos pares de entrada e saída das CNNs desenvolvidas. Dado os elevados índices de precisão pode-se afirmar também que os 4 segmentos modelo seleccionados para cada uma das modalidades da doença são apenas típicos dessa variante da doença.



## 8. CONCLUSÕES E TRABALHOS FUTUROS

### 8.1. Concretização dos objetivos

Num contexto de mudança constante, são vários os desafios aos quais os profissionais de saúde são obrigados a responder. A aposta no desenvolvimento de *softwares* de apoio ao diagnóstico é cada vez mais importante.

As doenças cardiovasculares não são exceção, até porque o estilo de vida adotado atualmente pela população leva a que cada vez mais se desenvolvam patologias associadas ao sistema cardiovascular. O EM é, efetivamente, uma das condições patológicas mais frequentes e com um prognóstico não tão promissor. Desta forma, é importante encontrarem-se soluções para um diagnóstico rápido e eficaz.

Um dos maiores desafios na deteção do EM é a identificação da área lesada. Este estudo apresentava como principal objetivo a deteção do EM anterior, anterolateral, inferior e inferolateral e para tal foram selecionados segmentos de sinal específicos de cada tipo de EM.

Os resultados obtidos foram, de um modo geral, bastante satisfatórios e promissores, demonstrando a possibilidade de identificação correta por parte das CNNs de eventos tipo das várias modalidades de estudo.

### 8.2. Trabalhos futuros

Em trabalhos futuros seria pertinente um aperfeiçoamento do algoritmo desenvolvido no presente estudo. Deste modo, seria conveniente ter em conta os seguintes pontos:

- Aumentar o número de características que permitam uma melhor identificação dos vários tipos de EM;
- Prolongar o presente estudo, no sentido de identificação dos outros tipos de EM que não foram estudados neste trabalho.
- Desenvolvimento de um algoritmo com capacidade discriminativa numa BD mais robusta com inclusão de outras patologias para além do GC e do EM, como por exemplo: arritmias, hipertrofias ventriculares, bloqueios de ramos, entre outros;
- Desenvolvimento de uma interface gráfica, com intuito de promoção do *software* na prática clínica.
- Publicação dos resultados numa revista de revisão internacional.



## Bibliografia

- [1] T. O. Takpor e C. Ndujuba, «ECG biosignal: Vital for detecting cardiovascular diseases», *Lect. Notes Eng. Comput. Sci.*, vol. 2223, pp. 519–522, 2016.
- [2] P. Guidelines, «Recomendações ESC de Bolso de 2018 Pocket da ESC Guidelines Comissão para as Committee for DO», 2018.
- [3] B. Ibanez *et al.*, «2017 ESC Guidelines for the management of acute myocardial infarction in patients presenting with ST-segment elevation», *Eur. Heart J.*, vol. 39, n. 2, pp. 119–177, 2018, doi: 10.1093/eurheartj/ehx393.
- [4] R. T. Giffoni e R. M. Torres, «Breve história da eletrocardiografia», *Rev. Med. Minas Gerais*, vol. 20, n. 2, pp. 263–270, 2010.
- [5] N. R. Borley, P. Collins, R. Alan, M. a Gatzoulis, J. C. Healy, e D. Johnson, *Library of Congress Cataloging in Publication Data Working together to grow libraries in developing countries*, 40th ed., vol. 57, n. 1. 2008.
- [6] A. Davies e A. Scott, *Starting to Read ECGs*. Springer, 2015.
- [7] J. L. Jameson, D. L. Kasper, D. L. Longo, A. S. Fauci, S. L. Hauser, e J. Loscalzo, *ECGs MADE EASY*, 6th ed. Elsevier, 2018.
- [8] H. Brooks, K. Barret, S. Boitano, e S. Barman, *Ganong's Review of Medical Physiology*, 23rd ed. 2010.
- [9] P. Jevon e J. Gupta, *Medical Student Survival Skills ECG*. 2020.
- [10] L. Schwarz, «Artigo de revisão: Eletrocardiograma», *Ilha Digit.*, vol. 1, pp. 3–19, 2009.
- [11] F. Kusumoto e P. Bernath, *ECG Interpretation for Everyone*. 2012.
- [12] A. Brahme, «Comprehensive biomedical physics», Newnes, 2014.
- [13] R. Jaros, R. Martinek, e L. Danys, «Comparison of different electrocardiography with vectorcardiography transformations», *Sensors (Switzerland)*, vol. 19, n. 14, pp. 1–19, 2019, doi: 10.3390/s19143072.
- [14] G. Gresham, «Cardiovascular Pathology», *J. Clin. Pathol.*, vol. 45, n. 6, pp. 53–92, 1992, doi: 10.1136/jcp.45.6.551-a.
- [15] F. J. Neumann *et al.*, «2019 ESC Guidelines for the diagnosis and management of chronic coronary syndromes», *Eur. Heart J.*, vol. 41, n. 3, pp. 407–477, 2020, doi: 10.1093/eurheartj/ehz425.

- [16] P. Libby e P. Theroux, «Pathophysiology of coronary artery disease», *Circulation*, vol. 111, n. 25, pp. 3481–3488, 2005, doi: 10.1161/CIRCULATIONAHA.105.537878.
- [17] E. Wilkins, L. Wilson, K. Wickramasinghe, e P. Bhatnagar, «European Cardiovascular Disease Statistics 2017», *Eur. Hear. Netw.*, pp. 94–100, 2017.
- [18] K. Thygesen, J. S. Alpert, e H. D. White, «Universal definition of myocardial infarction», *Eur. Heart J.*, vol. 28, n. 20, pp. 2525–2538, 2007, doi: 10.1093/eurheartj/ehm355.
- [19] J. V. Nable e W. Brady, «The evolution of electrocardiographic changes in ST-segment elevation myocardial infarction», *Am. J. Emerg. Med.*, vol. 27, n. 6, pp. 734–746, 2009, doi: 10.1016/j.ajem.2008.05.025.
- [20] D. G. Strauss e D. D. Schocken, *Practical Eletrocardiography*, 13th ed. Wolters Kluwer, 2014.
- [21] A. DİKER, Z. CÖMERT, e E. AVCI, «A Diagnostic Model for Identification of Myocardial Infarction from Electrocardiography Signals», *Bitlis Eren Univ. J. Sci. Technol.*, vol. 7, n. 2, pp. 132–139, 2017, doi: 10.17678/beuscitech.344953.
- [22] G. S. Wagner *et al.*, «Evaluation of advanced electrocardiographic diagnostic software for detection of prior myocardial infarction», *Am. J. Cardiol.*, vol. 89, n. 1, pp. 75–79, 2002, doi: 10.1016/S0002-9149(01)02170-1.
- [23] T. Lahiri, U. Kumar, H. Mishra, S. Sarkar, e A. Das Roy, «Analysis of ECG signal by chaos principle to help automatic diagnosis of myocardial infarction», *J. Sci. Ind. Res. (India)*, vol. 68, n. 10, pp. 866–870, 2009.
- [24] A. V. Bharadwaj, S. M. Upadhyaya, L. Sharath, e R. Srinivasan, «Early diagnosis and automated analysis of myocardial infarction (STEMI) by detection of ST segment elevation using wavelet transform and feature extraction», *Proc. - 2018 Int. Conf. Des. Innov. 3Cs Comput. Commun. Control. ICDI3C 2018*, pp. 24–28, 2018, doi: 10.1109/ICDI3C.2018.00014.
- [25] U. R. Acharya *et al.*, «Automated detection and localization of myocardial infarction using electrocardiogram: A comparative study of different leads», *Knowledge-Based Syst.*, vol. 99, n. 2016, pp. 146–156, 2016, doi: 10.1016/j.knosys.2016.01.040.
- [26] M. Arif, I. A. Malagore, e F. A. Afsar, «Detection and localization of myocardial infarction using K-nearest neighbor classifier», *J. Med. Syst.*, vol. 36, n. 1, pp. 279–289, 2012, doi: 10.1007/s10916-010-9474-3.
- [27] R. Bousseljot, D. Kreiseler, e A. Schnabel, «PTB Diagnostic ECG Database», 2004. .
- [28] U. F. Ervilha, M. Duarte, e a C. Amadio, «Estudo Sobre Procedimentos de Normalização do Sinal Eletromiográfico Durante o Movimento Humano», *Rev. Bras. Fisioter.*, vol. 3, n. 1, pp. 15–20, 1998.

- [29] R. Taylor, «Interpretation of the Correlation Coefficient: A Basic Review», *J. Diagnostic Med. Sonogr.*, vol. 6, pp. 35–39, 1990.
- [30] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang, e R. X. Gao, «Deep learning and its applications to machine health monitoring», *Mech. Syst. Signal Process.*, vol. 115, pp. 213–237, 2019, doi: 10.1016/j.ymssp.2018.05.050.
- [31] J. Schmidhuber, «Deep Learning in neural networks: An overview», *Neural Networks*, vol. 61, pp. 85–117, 2015, doi: 10.1016/j.neunet.2014.09.003.
- [32] B. Agarwal, V. E. Balas, L. C. Jain, R. C. Poonia, e M. Sharma, *Deep learning techniques for biomedical and health informatics*. 2020.
- [33] Y. Lecun, Y. Bengio, e G. Hinton, «Deep learning», *Nature*, vol. 521, n. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [34] A. Patil e M. Rane, «Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition», *Smart Innov. Syst. Technol.*, vol. 195, pp. 21–30, 2021, doi: 10.1007/978-981-15-7078-0\_3.
- [35] «MathWorks - Convolutional Neural Network». <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html>.
- [36] «Matlab&Simulink - Cross-Validation». <https://www.mathworks.com/discovery/cross-validation.html>.