

## DETECÇÃO DE ARRITMIAS CARDÍACAS: ABORDAGEM DA DERIVAÇÃO I COM REDES NEURAS HÍBRIDAS

DETECTION OF CARDIAC ARRHYTHMIAS: APPROACH OF LEAD I WITH HYBRID NEURAL NETWORKS

DOI: 10.16891/2317-434X.v12.e4.a2024.pp4585-4600

Recebido em: 27.05.2024 | Aceito em: 23.11.2024

**Augusto Felipe Maggioni<sup>a\*</sup>, Marcelo Trindade Rebonatto<sup>a</sup>**

**Programa de Pós-graduação em Computação Aplicada - Universidade de Passo Fundo - RS, Brasil<sup>a</sup>**  
**\*E-mail: 176387@upf.br**

### RESUMO

A Inteligência Artificial oferece mecanismos para predições na saúde beneficiando cada indivíduo assistida por ela. Os dispositivos inteligentes são aliados fundamentais para a extração e monitoramento de dados. O objetivo deste trabalho é construir um modelo de predição de arritmias cardíacas para Fibrilação Atrial e Bradicardia Sinusal, a partir de dados de Eletrocardiograma, que possa ser utilizado com dados coletados pelo aparelho multiclinico MP-IoT. O treinamento de Inteligência Artificial foi realizado aliando as técnicas de *Bidirectional Long Short-Term Memory*, *Convolutional Neural Network* e Redes Neurais Densas com dados obtidos a partir de duas bases disponíveis na *Physionet*. Um diferencial é o uso de apenas uma derivação de sinal, com resultados similares a outros trabalhos com uso de diversas derivações, obtendo métricas de avaliação acima de 96%.

**Palavras-chave:** Arritmias; Internet das Coisas; MP-IoT.

### ABSTRACT

Artificial Intelligence offers mechanisms for health predictions, benefiting each individual assisted by it. Smart devices are fundamental allies for data extraction and monitoring. The objective of this paper is to build a model for predicting cardiac arrhythmias for Atrial Fibrillation and Sinus Bradycardia, based on Electrocardiogram data, which can be used with data collected by the MP-IoT multiclinic device. The Artificial Intelligence training was carried out by combining the techniques of *Bidirectional Long Short-Term Memory*, *Convolutional Neural Network* and Dense Neural Networks with data obtained from two databases available on *Physionet*. The results obtained are promising for predictions with evaluation metrics above 96% of accuracy, precision, Recall, F1-score and specificity, even using only one derivation of the signal.

**Keywords:** Arrhythmias; Internet of Things; MP-IoT.

## INTRODUÇÃO

As tecnologias computacionais viabilizaram conhecimentos e descobertas na área médica, onde sistemas inteligentes são construídos para acelerar o reconhecimento de doenças e monitorar a saúde (GRECO *et al.*, 2020). Aliado a isso, é possível reduzir custos de consultas presenciais ao médico e crescimento da consciência de saúde pessoal (AKMANDOR; JHA, 2018; GRECO *et al.*, 2020). Essa atividade está associada ao progresso dos dispositivos da *Internet of Things* (IoT), uma vez que são capazes de medir, diagnosticar, monitorar e injetar pequenas dosagens precisas de medicamentos no corpo (AKMANDOR; JHA, 2018).

O eletrocardiograma (ECG) registra a atividade elétrica do coração, parte fundamental da avaliação cardiovascular, sendo essencial para a investigação de arritmias cardíacas. Eletrodos são colocados na superfície do corpo captando as variações das correntes elétricas geradas pela polarização e despolarização das células musculares do coração, captando ampla variedade de padrões (MEEK; MORRIS, 2002).

No histórico brasileiro, há um aumento significativo de mortes por doenças cardiovasculares desde a década de 1960. Em contrapartida, o sistema público ajudou a diminuir essa problemática, a fim de preservar vidas, mas ela continua de grande relevância (RIBEIRO *et al.*, 2016). Dados recentes de doenças cardiovasculares do Brasil (BRANT *et al.*, 2022) indicam que os riscos cardíacos representam a principal causa de mortalidade nas doenças cardiovasculares, principalmente por hábitos inadequados, exigindo investimentos e novas políticas de saúde pública.

A Fibrilação Atrial (AFIB) nos Estados Unidos, na China e na União Europeia desperta um fator de alerta devido ao aumento contínuo dos diagnósticos ao longo dos anos, além das estimativas para o futuro (ZHENG; GUO; CHU, 2024). Ademais, a COVID-19 tem forte participação no início de problemas cardíacos, levando a hipótese de ocorrência de lesão miocárdica, cardiomiopatia de estresse e choque cardiogênico (DE OLIVEIRA *et al.*, 2021). Esses problemas estão ligados a arritmias cardíacas, haja vista que danos causados no músculo ou aos nervos podem alterar a atividade elétrica do coração e induzir uma alteração correspondente nos ECGs (ZHENG *et al.*, 2020).

O dispositivo vislumbrado para uso neste trabalho é o Multiclínico MP-IoT (ELOMED, 2023). Nele, é possível coletar informações de oximetria,

pressão arterial, temperatura, frequência cardíaca e ECG. O objetivo deste trabalho consiste em detectar e distinguir as arritmias AFIB, *Sinus Bradycardia* (SB) e padrão cardíaco normal a partir de sinais de ECGs da derivação I, que podem ser coletados pelo MP-IoT. Para isso, duas bases públicas da *Physionet* (GOLDBERGER *et al.*, 2000) de sinais de ECGs foram processadas e usadas no treinamento.

## Modelos de inteligência artificial treinados

Diversos modelos de uso da IA podem ser encontrados na literatura, sendo alguns dos mais utilizados os algoritmos de Aprendizado de Máquina (*Machine Learning*) e Aprendizado Profundo (*Deep Learning*) (AHSAN; SIDDIQUE, 2022). A área de Aprendizado Profundo possui processamentos mais complexos. Dentre suas técnicas, encontram-se as *Long short-term memory* (LSTMs) que aprendem e memorizam dependências de longo prazo, recuperando informações passadas por longos períodos e eficiência em previsões de séries temporais, reconhecimento de fala, desenvolvimento farmacêutico, entre outras aplicações (MOHAMMADI *et al.*, 2018; SHERSTINSKY, 2020). A rede Convolutional Neural Network (CNN) é formada por múltiplas camadas e é intensamente usada principalmente para extração de características, por ter melhor resultado, em análise de imagens e vídeos (MOHAMMADI *et al.*, 2018). A técnica *Bidirectional Long Short-Term Memory* (Bi-LSTM) é semelhante à LSTM, mas com a vantagem de permitir feedback para a próxima camada, além de ser capaz de manipular dados com dependências de longo alcance (MOHAMMADI *et al.*, 2018; ZHU *et al.*, 2019). Por último, a técnica *Multi-Head Attention*, em que o foco é permitir que o modelo dê atenção a diferentes partes no processo de raciocínio na memória de forma simultânea e de várias perspectivas (FAN *et al.*, 2020).

Essas técnicas são amplamente utilizadas para processamentos de sinais, seja realizando por rede neural híbrida, nome utilizado quando se une/conecta mais de um tipo de algoritmo para chegar ao final de uma rede, seja utilizando apenas uma técnica.

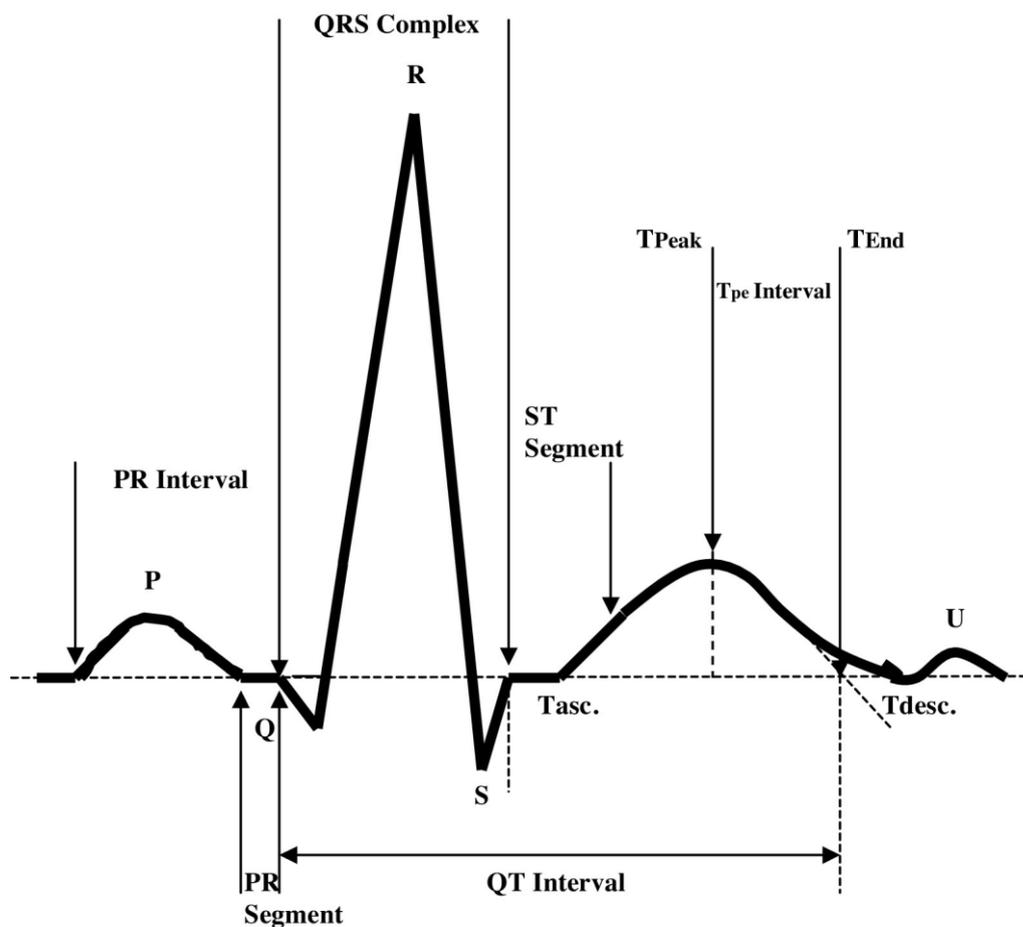
## Eletrocardiograma

O ECG é parte fundamental da avaliação cardiovascular, sendo essencial para a investigação de arritmias cardíacas. Além disso, é útil no diagnóstico de

distúrbios cardíacos, como infarto do miocárdio (MEEK; MORRIS, 2002). A Figura 1 ilustra um ciclo de ECG

completo a partir de suas posições e nomenclatura para cada ponto destacado.

Figura 1. Exemplo de um ciclo completo de ECG e suas posições.



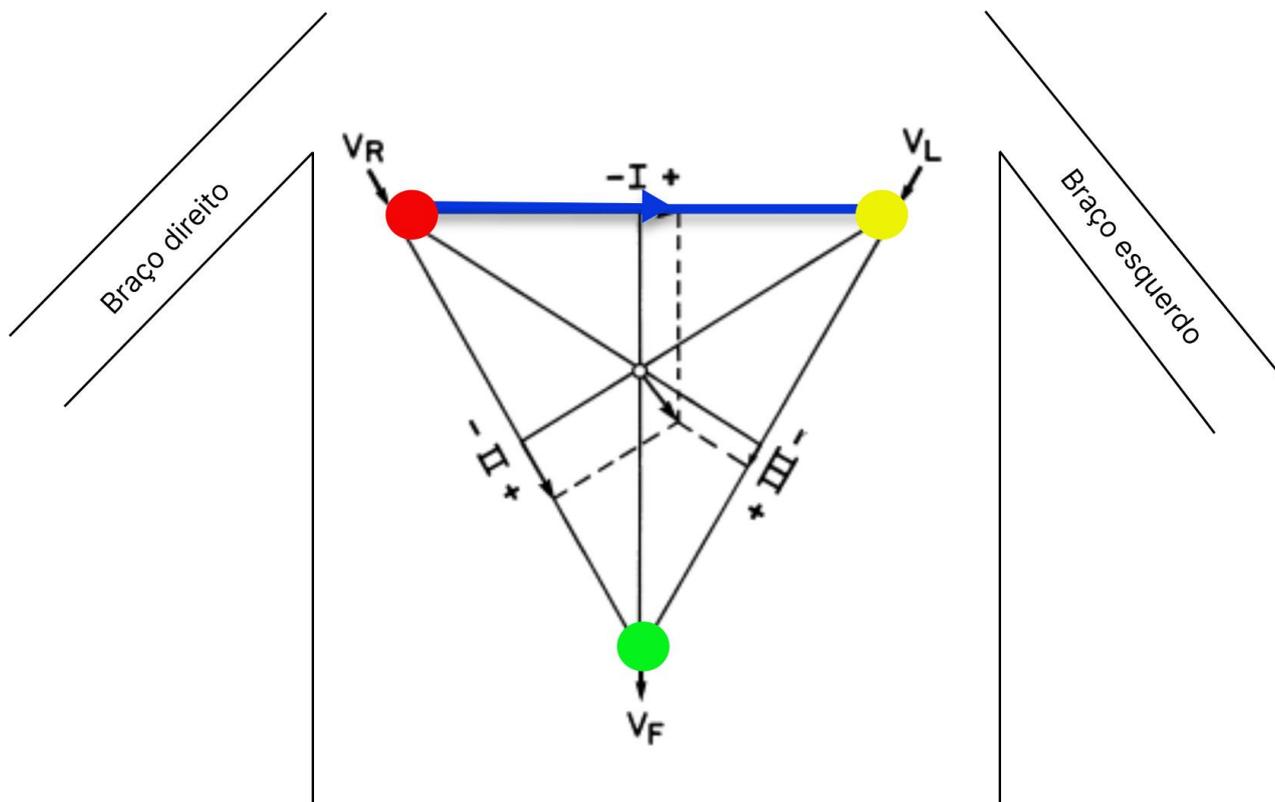
Fonte: Luz et al.(2016).

O ECG de um batimento cardíaco normal em ritmo sinusal apresenta três características: uma onda P apresentando a despolarização atrial, um complexo QRS denotando a despolarização ventricular e uma onda T representando a repolarização ventricular. A sequência característica normal do ciclo cardíaco é a onda P, o complexo QRS e a onda T com seções entre eles chamadas de segmentos (ZHENG *et al.*, 2020).

A contração e o relaxamento do músculo cardíaco resultam da despolarização e repolarização das células miocárdicas. Essas alterações elétricas são registradas por meio de eletrodos colocados nos membros

e na parede torácica e transcritas em papel quadriculado para produzir um ECG. Dependendo da posição dos eletrodos na superfície do corpo, produz derivações que devem ser analisadas e observadas em diferentes pontos de vista. Elas podem variar em 12 derivações: torácicas (V1 a V6) e membros (I, II, III, aVR, aVL e aVF) (MEEK; MORRIS, 2002). As derivações dos membros são conhecidas pelo triângulo de Einthoven que representa a projeção dos vetores dos eixos dos membros (Figura 2), sendo VR lado direito e VL lado esquerdo do corpo (SURAWICZ; KNILANS; CHOU, 2008).

Figura 2. Triângulo de Einthoven.



Fonte: Adaptado de Surawicz; Knilans; Chou (2008).

Arritmias cardíacas são distúrbios no ritmo do coração em que os batimentos podem ser rápidos, irregulares ou mais lentos que o normal. Para o ritmo mais rápido, encontram-se a AFIB e *flutter atrial* em que a onda QRS pode ser mais larga que o normal, mostrando uma despolarização ventricular mais prolongada. Arritmias de ritmo mais lento (SB), são caracterizadas quando o nó sinoatrial, conhecido como marcapasso do coração, gera impulsos elétricos em frequência mais lenta, resultando em uma frequência cardíaca abaixo do normal (entre 50, 60 a 100 bpm) (FENGLER; BRADY; PLAUTZ, 2007; MEEK; MORRIS, 2002).

O MP-IoT é um dispositivo multifuncional (Figura 3) que realiza a coleta automática de oximetria, pressão arterial, temperatura, frequência cardíaca e de ECG. Ele é capaz de capturar as informações e enviar os dados via *Bluetooth* para o aplicativo eProHealth (VISIONNIT, 2024), onde é possível acompanhar o histórico de coletas e estatísticas do usuário. Além disso, com o aplicativo pode-se autorizar um médico (ou profissional de saúde) a acessar e acompanhar os dados coletados do paciente.

**Figura 3.** Dispositivo Multiclínico MP IoT.



Fonte: ELOMED (2023).

Para a coleta do ECG, são disponibilizados três eletrodos que devem ser colocados em locais específicos do corpo, representado cada eletrodo por uma cor: verde ( $V_F$ ), vermelho ( $V_R$ ) e amarelo ( $V_L$ ) (Figura 2). A coleta do ECG pode ser realizada com três derivações: DI, DII ou DIII, dependendo da posição de cada cor do eletrodo no corpo. Neste trabalho será utilizada a derivação I (Figura 2) por padrão de uso do MP-IoT.

A duração de cada coleta de ECG do MP-IoT contém aproximadamente 9,6 segundos. O sensor é baseado no circuito integrado 8232 (ANALOG DEVICES, 2023), configurado para capturar amostras a 250 Hz armazenando 2.400 valores. O sinal contém apenas valores positivos oriundos do conversor analógico digital.

#### ***Aplicações de IA em sinais de Eletrocardiograma***

A medicina de precisão, esfera da saúde em que IoT e IA trabalham juntas para proporcionar maior precisão em diagnósticos e facilitar o monitoramento constante do paciente, possui grande possibilidade de revolucionar o sistema de saúde (AGARWAL *et al.*, 2021). Para essa finalidade, aliar esses dispositivos com a

IA em tempo real, é um dos maiores desafios para essa área (MOHAMMADI *et al.*, 2018).

Diversos trabalhos utilizam técnicas de IA para prognóstico na área de saúde, entre eles, na cardiologia. O trabalho de Zhu (ZHU *et al.*, 2019) utiliza Bi-LSTM e CNN para reconhecer padrões eletrocardiológicos com 12 derivações e sem descrição de limitações de frequência, haja vista o duplo direcionamento que possui, podendo ser uma vantagem quanto ao algoritmo LSTM utilizado no estudo de (CHEN *et al.*, 2022). O artigo de Agarwal *et al.* (2021) aplica algoritmos de *Deep Learning* para previsões de riscos cardiovasculares e auxiliar na interpretação de imagens médicas. O estudo de Chen *et al.* (2022) empregou técnicas de LSTM e CNN para prever mortalidades na base de dados MIMIC IV.

A pesquisa da equipe de Soadun Simanjuntak (SOADUON SIMANJUNTAK; KHODRA; TOSIMA MANULLANG, 2020) utilizou dispositivos IoT junto a uma rede RNN para previsões de AFIB em coleta de ECG de 10 segundos. No trabalho de Oliveira (OLIVEIRA *et al.*, 2022), os autores extraíram diversos atributos do sinal do ECG para classificar o conjunto de quatro arritmias (SR, AFIB, GSVT e SB). Utilizou-se a

combinação dos modelos *XGradient Boost*, *Random Forest* e *Gradient Boost* para a criação do modelo a fim de melhorar a performance de classificação.

O estudo de Faust (FAUST *et al.*, 2018) conseguiu detectar a arritmia AFIB a partir de um modelo LSTM bidirecional com 60 a 80 épocas e 10 *folders* de validação cruzada. Liu (LIU *et al.*, 2022) e He (HE *et al.*, 2018) utilizaram em suas pesquisas CNNs para detectar AFIB, chegando a resultados semelhantes a Faust (FAUST *et al.*, 2018), mas não consideram cenários de medição e avaliação que empregam aparelhos de monitoramento pessoal portátil, como o MP-IoT.

Nos trabalhos descritos não há informações explícitas de quantas derivações do ECG são usadas, exceto o trabalho de Zhu (ZHU *et al.*, 2019), e o limite de frequência do sinal. Foram descritos sinais com frequência de amostragem de 500 Hz, variando o tempo de coleta para cada autor. Em resumo, a literatura dispõe de trabalhos correlatos com o objetivo de detectar arritmias a partir de sinais de ECG, mas não consideram cenários de medição e avaliação que empregam aparelhos de monitoramento pessoal portátil, como o MP-IoT. Dessa forma, o presente trabalho possui um conjunto características únicas, tais como faixa de frequência limitada de 0.05 a 30Hz, frequência de amostragem de 250 Hz, e de apenas uma derivação (DI) para predição de arritmias ou da normalidade. As condições foram balizadas para uso com coletas realizadas pelo MP IoT.

## MATERIAIS E MÉTODOS

Esta seção detalha as etapas e metodologias realizadas, desde a preparação da base de dados, até a validação do modelo da IA em ambiente real. A preparação da base de dados contempla os filtros utilizados e as técnicas aplicadas nas amostras. Por último, são delineados os métodos e algoritmos de aprendizagem de máquina para a formalização da IA treinada.

### Base de processamento

A base de dados deste trabalho foi criada a partir de duas bases de dados públicas (ZHENG; GUO; CHU, 2024) e (WAGNER *et al.*, 2024) disponíveis a partir da *Physionet* (GOLDBERGER *et al.*, 2000). Após a união das bases, os dados foram processados para chegar a base final com 44.217 registros classificados somente como arritmias e normal a partir de especialistas em

cardiologia. Ambas as bases contêm 12 derivações, de 500Hz em 10 segundos, dispondo de 5.000 amostras de sinais para cada eletrocardiograma. Dessa forma, foi preciso fazer a redução de frequência usando a interpolação cúbica, técnica utilizada por criar curvas mais suaves, preservar detalhes dos dados e menos suscetível a problemas de sobreajustes ou instabilidade (GALLAGHER, 2005).

O *dataset* 'A large scale 12-lead electrocardiogram database for arrhythmia study' (ZHENG; GUO; CHU, 2024) possui dados de 45.152 de eletrocardiogramas com classificações de arritmia, condução, hipertrofia e infarto a partir de especialistas em cardiologia. Sua base de dados é composta de arquivos no formato *WaveForm DataBase* (WFDB) contendo informações e características de cada ECG.

O *dataset* 'PTB-XL, a large publicly available electrocardiography dataset' (WAGNER *et al.*, 2024) possui 21.837 dados classificados em normal, infarto, condução, hipertrofia e alterações da onda ST/T. Foram selecionados 6.094 sinais classificados como normais dos eletrocardiogramas.

### Filtros

De acordo com *American Heart Association* (AHA), qualquer anomalia na sequência regular dos sinais elétricos da frequência cardíaca é considerada arritmia. Os filtros são necessários para remover interferências ou atenuar ruídos, preservando padrões e evitando ao máximo a perda de informação (CHEN *et al.*, 2022).

### Rede elétrica

O filtro *Infinite Impulse Response* (IIR), *notch*, é um filtro digital utilizado para atenuar frequências específicas de um sinal. Ele é utilizado no processamento de sinais de ECG para remover interferências de frequências específicas, artefatos musculares e interferências de equipamentos médicos (YING-WEN BAI *et al.*, 2004). Como os dados das bases de treinamento são provenientes do país da República Popular da China, a rede elétrica padrão é de 50Hz. Apesar de Karri e Annavarapu (KARRI; ANNAVARAPU, 2023) utilizarem Transformada Wavelet Discreta (DWT) para detecção de anomalias de diferentes tamanhos e frequências no sinal de ECG, principalmente para os complexos QRS, o filtro *notch*

tem como característica apenas remover as interferências da rede elétrica, já que processos de passa banda ainda não são aplicados para reduzir a frequência do que é captado pelo MP-IoT.

### ***Filtro passa-banda de Butterworth***

O filtro passa-banda é uma técnica que permite a remoção de frequências indesejadas e a preservação das informações relevantes em sinais de ECG. Esse tipo de filtro permite a passagem das frequências que estão dentro de uma faixa pré-definida, enquanto atenua as frequências que estão fora dessa faixa. Dessa forma, os filtros aplicados não apresentam risco significativo de perda de informações relevantes durante o processo, apenas em função do índice de corte utilizado (JAGTAP; UPLANE, 2012). O filtro passa-banda de *Butterworth* foi aplicado em duas etapas durante o processamento: a primeira aplicação ocorreu após a filtragem da rede elétrica, com uma ordem de 4; a segunda aplicação foi realizada na etapa final do processamento, com uma ordem de 2. A ordem do filtro indica o número de estágios, o que afeta a atenuação das frequências e a taxa de passa-banda (SELESNICK; BURRUS, 1998), quanto maior o valor da ordem, mais eficaz é a filtragem. Em ambas as etapas, foram utilizados filtros com 0,05 Hz para passa-alta e 30 Hz para passa-baixa.

### ***Suavização de Loess***

O filtro *Local Regression Scatterplot Smoothing* (LOESS) foi escolhido para suavizar os sinais. Esse filtro tem como função combinar técnicas de regressão polinomial local com uma janela de ponderação (nove) que dá mais pesos aos pontos próximos do ponto que está sendo estimado. É útil para remover os ruídos de baixa frequência, sendo muito utilizado em processamento de sinais (RAHUL; SORA; SHARMA, 2019). Zheng (ZHENG *et al.*, 2020) utilizou esse filtro para

classificação de arritmias através do *dataset* ‘*A large scale 12-lead electrocardiogram database for arrhythmia study*’. O filtro foi aplicado depois do filtro passa-banda de *Butterworth* com o tamanho de janela definido em 10. Esse valor é pequeno para cada fração de cálculo a fim de não ocorrer tanta variação e preservar o sinal.

### ***Interpolação cúbica e deslocamento***

A interpolação cúbica para sinais de ECG é uma técnica baseada na aproximação de polinômios cúbicos entre os pontos conhecidos, permitindo a reconstrução do sinal com um aumento ou diminuição na frequência de amostragem. É usada para estimar os valores desconhecidos entre os pontos conhecidos em um sinal de ECG (GALLAGHER, 2005). Dessa forma, é utilizada a Interpolação cúbica para diminuir a frequência de 500Hz, amostras padrão das duas bases selecionadas, para 250Hz, a frequência de coleta do MP-IoT. Em (KWON *et al.*, 2018) é descrito que realizar a interpolação linear de 500Hz para 250Hz fornece bons resultados. O deslocamento é um processo realizado para que os valores das amostras do sinal de ECG fiquem positivos, sem exceção, pois os valores que o MP-IoT coleta são positivos. Logo, para que ocorra proporcionalidade entre os dados, essa técnica é fundamental para que não ocorra perda de informações relevantes. O valor mínimo de cada amostra de sinal foi definido em 1.

### ***Base final***

A base de dados final, usada para treinamento e testes neste trabalho, contém sinais de ECG com arritmias do tipo AFIB, *Sinus Irregularity* (SI) e SB, além de ECGs considerados normais. A Tabela 1 contém a quantidade inicial e final de amostras que cada classe possui.

**Tabela 1.** Quantidade de amostras selecionadas da base inicial e para treinamento.

Classe	Subclasse	Quantidade	
		Inicial	Final
Arritmias	AFIB	1.780	1.780
	SB	16.559	1.780
	SI	2.550	1.780
Normal	-	6.103	1.780

Ao analisar a Tabela 1 pode-se observar que as classes rotuladas estão desbalanceadas. Torna-se necessário equilibrar a quantidade de classes para um mesmo valor, ou com pouca diferença, processo essencial para reduzir as possibilidades de *overfitting* e melhorar as métricas de classificação da IA. A classe AFIB dispõe da menor quantidade de dados classificados, com 1.780 casos. Foram então escolhidas de forma aleatória 1.780 amostras das outras classes, finalizando a base com 7.120 linhas de treinamento distribuídas igualmente entre as classes. A base final contém informações de sexo, idade e de qual arquivo pertence esses dados. A última etapa da preparação da base final antes do treinamento consistiu em normalizar os dados com *MinMaxScaler* (PEDREGOSA, F. *et al.*, 2011) no intervalo de 0 a 10 e dividir os dados para treinamento, teste e validação.

Como resultado desses processos, o *dataset* se encontra disponível na plataforma *Dataverse* de Harvard, em conjunto com o Centro de Inteligência Artificial Aplicada à Saúde (CIARS). No total, há 5.340 amostras de sinais da derivação I anotadas prontas para serem utilizadas em treinamentos (MAGGIONI; REBONATTO, 2023).

### **Versões da rede híbrida convolucional bidirecional**

Diversos testes foram realizados até chegar ao modelo com melhor desempenho, variando os hiperparâmetros, as arquiteturas, suas quantidades de neurônios e em diferentes posições. Ao todo, cinco versões foram construídas e testadas. Todas as versões utilizaram a mesma quantidade de camadas, neurônios e usaram *dropout*. O *dropout* é uma técnica com finalidade de forçar a rede a aprender características independentes a cada neurônio, esquecendo-os a partir de um subconjunto aleatório em cada camada, tornando a rede

mais robusta e menos sensível à variação dos dados. As versões com CNN usaram *Max Polling*, processo em que um conjunto de neurônios é reduzido a fim de diminuir a dimensão de cada camada e preservar as características, além de ajudar a lidar com problemas de sobre ajustes (SRIVASTAVA *et al.*, 2014).

As redes CNNs utilizadas foram compostas de 256 neurônios, com exceção da RHCB5 que utilizou 3 camadas, com 256, 128 e 64. As redes Bi-LSTM utilizadas possuem 1 camada na RHCB5 com 256 neurônios e duas com 256 e 128 em sequência na RHCB2. As camadas densas foram compostas por 4 camadas de 256, 128, 64 e 4 neurônios.

Utilizando camadas CNN (RHCB1), a rede consegue chegar aos 92% nas métricas de avaliação. Quando utilizado LSTM ou Bi-LSTM (RHCB2), o modelo não conseguiu distinguir as classes, com métricas ficando em cerca de 20 a 35%. Ao utilizar CNN e camadas densas (RHCB3), o desempenho fica em torno de 50 a 60% nas métricas de acurácia e precisão. Quando adicionado camadas de atenção (FAN *et al.*, 2020) no lugar da Bi-LSTM (RHCB4), o desempenho fica semelhante, mas nas métricas de desempenho ocorre grande variação na aprendizagem. Quando adicionado no início da rede, o desempenho cai e o tempo aumenta, isso com duas cabeças. Com apenas uma cabeça, mas com 128 neurônios, ocorre o *overfitting* resultando entre 70 a 80% nas métricas de precisão e acurácia.

Ao construir o RHCB5 com CNN e Bi-LSTM, com poucos neurônios (16 e 32) e (32, 64), respectivamente, a rede fica instável e acaba não aprendendo. Além disso, com poucas camadas na rede ocorre o *overfitting*. Ao aumentar a quantidade de neurônios, (256 e 512) com duas ou mais camadas, o tempo de processamento ficou elevado além de ocorrer *overfitting*. Ressalta-se que ao utilizar no mínimo duas

camadas consecutivas Bi-LSTM, a aprendizagem piora bastante, ficando em cerca de no máximo 40% na validação dos dados. A rede RHCB5 final (Figura 4) alcançou as maiores métricas de validação e testes, como observado na Tabela 2 e na Tabela 3. Na validação cruzada com cinco ou 10 *folders*, não houve diferenças nos resultados. Entretanto, ao utilizar cinco *folders* a rede ficou mais estável durante o treinamento.

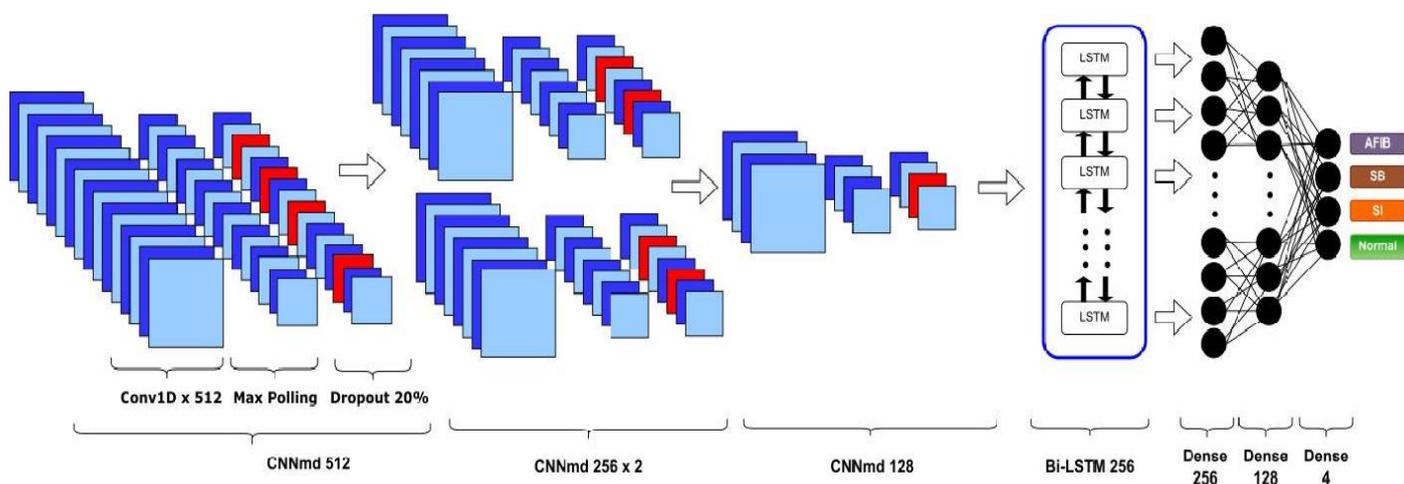
### Rede híbrida convolucional bidirecional 5 (RHCB5)

A IA RHCB5 recebe como entrada um sinal de 2.400 amostras nas camadas CNN, seguida por outras três redes CNN de uma dimensão (Conv1D). Os *kernels* foram configurados em 3 (valor padrão). Sua função é aplicar filtros a partir de uma matriz de pesos de diferentes valores a fim de extrair variadas características em cada camada.

Depois das camadas CNN, a rede possui uma camada Bi-LSTM de 256 células que não sofreu

modificações de parâmetros a partir da configuração padrão. Por fim, as três últimas camadas são compostas por redes densas, iniciando com 256 neurônios e *dropout* de 40%, seguido de outras duas camadas densas de 128 e 4 neurônios, sem *dropout*. As camadas possuem função de ativação *ReLU*, exceto a última camada de saída que possui a ativação *softmax*. A função de ativação *ReLU* tem como propriedade retornar valores zeros para todos os valores negativos calculados, enquanto valores positivos ficam ativados na rede. Ela é computacionalmente eficiente, deixa a rede menos sensível, sendo capaz de ajudar a evitar o *overfitting* (SRIVASTAVA *et al.*, 2014). A ativação *softmax* é utilizada para classificação multiclasse, retornando a probabilidade de saída para cada classe treinada (AFIB, SB, SI e normal) (WANG *et al.*, 2018). A função de perda (*loss*) é definida como *Categorical Crossentropy* (HO; WOOKEY, 2020) devido a rede ser de classificação e os rótulos estão no formato de vetores *one-hot*.

Figura 4. Representação da rede RHCB em sua 5a versão.



Na RHCB5 (Figura 4) CNNmd512 significa uma rede CNN com 512 neurônios, CNNmd 256 x 2 duas redes CNN com 256 neurônios, CNNmd 128 uma rede CNN com 128 neurônios. Ainda na Figura 4, Bi-LSTM 256 é uma rede Bi-LSTM com 256 neurônios e Dense 256, 128, 4 são as camadas densas com suas respectivas quantidades de neurônios. Entre a dense 256 e 128, ocorre *dropout* de 40%. O número de épocas ficou em 60 (FAUST *et al.*, 2018) e o número de lotes foi definido em 32. Após diversos testes com os mesmos dados,

observou-se que essa configuração obteve as melhores métricas.

Em toda a rede RHCB5 foi utilizada a função de otimização *Adam*, responsável por medir o quão longe as previsões do modelo estão dos valores reais (rótulos) nos dados de treinamento (REDDI; KALE; KUMAR, 2019), comumente utilizadas nos trabalhos relacionados (FAUST *et al.*, 2018; OLIVEIRA *et al.*, 2022; SOADUON SIMANJUNTAK; KHODRA; TOSIMA MANULLANG, 2020; WANG *et al.*, 2018; ZHENG *et*

al., 2020; ZHOU *et al.*, 2022) por apresentar melhores resultados.

### Validação cruzada

Ao total, o *dataset* possui 7.120 linhas, classificadas em AFIB, SB, SI e normal. Para o treinamento foram utilizadas 80% das amostras de cada classe e para a validação 20% (356 amostras de cada classe). Após, a base foi dividida em cinco *folders* na validação cruzada. Isso significa que um dos *folders* é reservado para validação, utilizando 20% dos ECGs de treinamento, enquanto os 80% restantes são usados para o treinamento. Depois desse primeiro processo, o *folder* reservado para validação é usada para teste, e o *folder* que estava reservada para teste é incorporada aos dados de treinamento (ARLOT; CELISSE, 2010). Isso é importante para que o modelo consiga se adaptar e evitar o *overfitting*, porém aumenta o tempo de processamento.

A escolha do melhor modelo se define no menor *loss* alcançado durante o treinamento das 300 iterações, 60 épocas com *folders* de cinco. A definição do *checkpoint* é importante por armazenar e comparar ao final de cada época a métrica de *loss*, preservando o modelo que possui o menor valor.

## RESULTADOS

Nesta seção, serão apresentados os resultados obtidos a partir das análises e experimentos realizados. O objetivo é fornecer uma visão detalhada dos dados coletados com métricas e observações que surgiram

durante o processamento e avaliação dos modelos. A interpretação dos dados permitirá discutir as implicações dos resultados e fornecer recomendações baseadas nas evidências coletadas.

### Ambiente computacional de desenvolvimento e testes

Os experimentos foram realizados através da plataforma Google Colab (<https://colab.google>) com processador Intel(R) Xeon(R) de 2,00GHz, 12,7GB de memória RAM e GPU Tesla T4. O período de execução do treinamento, testes e validação ocorreu entre os meses de maio e junho de 2023. Esse tempo foi necessário para o planejamento, implementação e execução dos modelos a fim de construir uma IA com a menor taxa de erro a partir de um *checkpoint* que salva a cada época a rede com os pesos. A linguagem de programação utilizada no desenvolvimento foi *Python*.

### Comparativo dos resultados obtidos

A fim de avaliar o desempenho de classificação do modelo, as métricas acurácia, precisão, *Recall*, *F1-score* e especificidade foram avaliadas durante o treinamento. A Tabela 2 contém os resultados comparativos dos cinco modelos submetidos ao treinamento para as três classes (AFIB, SB e Normal). Os resultados com uso de quatro classes foram piores e não serão analisados neste trabalho, pois a rede não conseguiu distinguir com eficácia as classes SB e normal, seja pela limitação de frequência seja pela característica do sinal.

**Tabela 2.** Resultados com dados de testes das versões dos modelos RHCb com 3 classes.

Modelo	Acurácia	Precisão	Recall	F1-Score	Especificidade
RHCb 1	92,13%	92,57%	92,13%	92,11%	92,17%
RHCb 2	37,92%	38,30%	37,92%	36,55%	69,67%
RHCb 3	56,83%	59,59%	56,83%	55,02%	77,17%
RHCb 4	93,53%	63,69%	93,53%	93,51%	96,74%
RHCb 5	96,91%	96,91%	96,90%	96,90%	98,40%

Ao analisar o resultado do modelo RHCb5 com três classes em relação ao trabalho de Faust (FAUST *et al.*, 2018) e Soadun (SOADUON SIMANJUNTAK;

KHODRA; TOSIMA MANULLANG, 2020), que utilizaram as técnicas de LSTM bidireccional e RNN, respectivamente, para detectar AFIB, observa-se que a

rede RHCBS5 conseguiu um bom desempenho em relação ao estudo dos autores. Entretanto, é importante ressaltar que em ambos os estudos não é especificado quantas e quais derivações de ECG foram utilizadas, informações que são importantes ao avaliar o desempenho na detecção de arritmias. Além disso, não houve limitação de amplitude (filtro passa-banda de 0,05 a 30Hz) e frequência de captura (interpolação cúbica para 250 Hz).

O trabalho de Liu (LIU *et al.*, 2022) utilizou a rede CNN para classificação binária a fim de detectar AFIB em relação aos ECGs que não possuíam rótulo de AFIB, com métricas em cerca de 97%. A rede RHCBS5 apresentou desempenho equivalente ao trabalho (LIU *et al.*, 2022), com uma taxa de 1 a 2% menor. Apesar do desempenho ser próximo, destaca-se que essa diferença pode existir, possivelmente, pela quantidade de classes a ser previstas (três), assim como, pela redução da frequência de amostragem perante aos processos da interpolação cúbica de 500 para 250Hz, processo que pode causar uma perda de informação aos sinais das amostras do ECG.

A pesquisa de Zhu (ZHU *et al.*, 2019) que aliou as técnicas de CNN e Bi-LSTM para padrões de ECG de 12 derivações, conseguindo métricas de cerca de 99% para classificação de AFIB enquanto a rede RHCBS5

apresentou desempenho próximo com arquitetura similar. Apesar do resultado semelhante (96%), essa pequena diferença pode ser explicada, embora o autor não tenha deixado claro quantas derivações foram utilizadas para o treinamento e se houve limitações de amplitudes e frequência da onda. Os resultados da RHCBS5 apresentam limitações e características únicas, tais como limitações de amplitudes, frequências das amostras de ECG e a quantidade de derivações.

### Testes com simulador

O simulador *Fluke ProSim 4 Vital Signs Simulator* (FLUKE, 2024) foi utilizado para gerar amostras de ECGs com arritmias AFIB, SB, Bloqueio Atrioventricular, Assistolia, Fibrilação Ventricular (Grossa, fina, 160 bpm e 200 bpm) e normais. A frequência de amostragem é de 250 Hz com 9,6 segundos de duração resultando em aproximadamente 2.400 amostras por ECG. Não houve limitação de amplitude da onda, ruídos e demais possíveis irregularidades para cada ECG. Para a coleta, o simulador foi conectado as entradas de dados do MP-IoT, simulando os sinais de uma pessoa. A Tabela 3 contém os ECGs gerados pelo simulador e a predição da rede RHCBS5 de 3 classes.

**paperTabela 3.** Relação entre os eventos gerados pelo simulador e a predição do modelo RHCBS5 com 3 classes.

ID	Evento	Predição	AFIB (%)	SB (%)	NORMAL (%)
1	Fibrilação Atrial Fina	AFIB	99,99	0,00	0,01
2	Fibrilação Atrial Grossa	AFIB	99,97	0,00	0,03
3	Normal 210 BPM	AFIB	99,96	0,00	0,04
4	Normal 150 BPM	Normal	32,60	0,00	67,40
5	Normal 90 BPM	Normal	0,00	0,00	100
6	Normal 60 BPM	Normal	0,02	0,84	99,14
7	Normal 30 BPM	SB	0,23	99,54	0,23
8	Assistolia	SB	0,62	99,05	0,33
9	Bloqueio Atrioventricular (BAVT) - 3º grau	SB	7,07	89,76	3,17
10	Bloqueio Atrioventricular (BAVT) - 1º grau	AFIB	99,99	0,00	0,01

11	Fibrilação Ventricular Fina	AFIB	99,17	0,06	0,78
12	TV Paced 75 BPM	AFIB	99,96	0,01	0,03
13	Fibrilação Ventricular Grossa	AFIB	98,15	0,10	1,76
14	Taquicardia Ventricular 160BPM	AFIB	99,99	0,01	0,00
15	Taquicardia Ventricular 200 BPM	AFIB	99,59	0,01	0,04

Ao analisar os IDs 1, 2, 3, 4, 5, 6 e 7, considerando que o ID 3 (Normal 210 BPM) pode ser considerado uma arritmia do tipo AFIB (alto batimento cardíaco acima de 200 BPM), assim como o ID 7 (Normal 30 BPM) pode ser classificado como uma arritmia do tipo SB, abaixo de 60 BPM, a rede RHCB5 obteve 100% de acertos.

Além disso, ao analisar os IDs 8, 9, 10, 11, 12, 13, 14 e 15, em que todos são anomalias cardíacas e sabendo que o modelo RHCB5 foi treinado apenas com AFIB, SB e normal, observa-se que todas as predições foram classificadas para um dos tipos de arritmias treinadas (AFIB ou SB). Essa análise é importante, pois, mesmo quando o sinal simulado continha uma irregularidade cardíaca, diferente das que o RHCB5 foi treinado, ela conseguiu identificar como anormalidade em vez de considerá-la como normal. Essa descoberta ressalta a importância de o paciente buscar a opinião de um cardiologista.

## CONSIDERAÇÕES FINAIS

O objetivo deste trabalho foi desenvolver uma rede híbrida de IA utilizando técnicas de CNN, Bi-LSTM e redes densas para a detecção das arritmias AFIB, SB e diferenciá-las de um ECG normal. Ao longo desta pesquisa, buscou-se criar um modelo eficiente e preciso capaz de auxiliar na identificação precoce e no monitoramento dessas arritmias.

Neste trabalho, foram treinadas várias redes para detectar arritmias, utilizando configurações com três e quatro classes. A rede com três classes demonstrou a

melhor eficiência nas métricas de avaliação em relação a rede com quatro classes. Esses resultados estão possivelmente relacionados à dificuldade da rede em aprender e distinguir corretamente as quatro classes simultaneamente com apenas uma derivação analisada. Esse problema pode ser atribuído à necessidade de mais dados para treinamento ou à sobreposição das características das quatro classes.

A partir dos resultados, constatou-se que a rede híbrida alcançou desempenho promissor na detecção precoce das arritmias, mesmo com as suas limitações. A detecção de arritmias cardíacas é crucial para a prevenção de complicações e oportuna intervenção médica. O desenvolvimento desta rede híbrida de IA representa um avanço importante na detecção de arritmias cardíacas e seu acompanhamento, que poderá ser utilizado em conjunto com equipamentos portáteis de telemonitoramento, como o MP-IoT. Para isso, a coleta e o uso de conjuntos de dados em maior quantidade e mais diversificados, rotulados a partir da extração do MP-IoT junto a um médico especialista em cardiologia, podem melhorar o desempenho do modelo RHCB5.

## AGRADECIMENTOS

Agradecemos a Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS) pelo apoio ao estudo, por meio do projeto de pesquisa CIARS (60116.671.27164.23122021), aprovado no Edital FAPERGS 06/2021 Programa de Redes Inovadoras de Tecnologias Estratégicas do Rio Grande do Sul – RITES-RS.

## REFERÊNCIAS

- AGARWAL, Neha; SINGH, Pushpa; SINGH, Narendra; SINGH, Krishna Kant; JAIN, Rohit. Machine Learning Applications for IoT Healthcare. *In: SINGH, Krishna Kant; SINGH, Akansha; SHARMA, Sanjay (orgs.). Machine Learning Approaches for Convergence of IoT and Blockchain*. 1. ed. Beverly: Wiley, 2021. p. 129–144. DOI 10.1002/9781119761884.ch6. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1002/9781119761884.ch6>. Acesso em: 23 fev. 2024.
- AHSAN, Md Manjurul; SIDDIQUE, Zahed. Machine learning-based heart disease diagnosis: A systematic literature review. **Artificial Intelligence in Medicine**, v. 128, p. 102289, jun. 2022. <https://doi.org/10.1016/j.artmed.2022.102289>. Acesso em: 18 fev. 2024
- AKMANDOR, Ayten Ozge; JHA, Niraj K. Smart Health Care: An Edge-Side Computing Perspective. **IEEE Consumer Electronics Magazine**, v. 7, n. 1, p. 29–37, jan. 2018. DOI: <https://doi.org/10.1109/MCE.2017.2746096>. Acesso em: 26 abr. 2023.
- ANALOG DEVICES. DataSheet AD 8232. 2023. Disponível em: <https://www.analog.com/media/en/technical-documentation/data-sheets/ad8232.pdf>. Acesso em: 7 mar. 2023.
- ARLOT, Sylvain; CELISSE, Alain. A survey of cross-validation procedures for model selection. **Statistics Surveys**, v. 4, n. none, 1 jan. 2010. DOI: <https://doi.org/10.1214/09-SS054>. Acesso em: 22 fev. 2024.
- BRANT, Luisa Campos Caldeira; NASCIMENTO, Bruno Ramos; VELOSO, Guilherme Augusto; GOMES, Crizian Saar; POLANCZYK, Carisi; OLIVEIRA, Gláucia Maria Moraes De; FLOR, Luisa Sorio; GAKIDOU, Emmanuela; RIBEIRO, Antonio Luiz Pinho; MALTA, Deborah Carvalho. Burden of Cardiovascular diseases attributable to risk factors in Brazil: data from the “Global Burden of Disease 2019” study. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 55, n. suppl 1, p. e0263-2021, 2022. DOI: <https://doi.org/10.1590/s0037-8682-0263-2021>. Acesso em: 28 mai. 2023.
- CHEN, Yu-wen; LI, Yu-jie; DENG, Peng; YANG, Zhi-yong; ZHONG, Kun-hua; ZHANG, Li-ge; CHEN, Yang; ZHI, Hong-yu; HU, Xiao-yan; GU, Jian-teng; NING, Jiao-lin; LU, Kai-zhi; ZHANG, Ju; XIA, Zheng-yuan; QIN, Xiao-lin; YI, Bin. Learning to predict in-hospital mortality risk in the intensive care unit with attention-based temporal convolution network. **BMC Anesthesiology**, v. 22, n. 1, p. 119, dez. 2022. DOI: <https://doi.org/10.1186/s12871-022-01625-5>. Acesso em: 5 jun. 2023.
- DE OLIVEIRA, Vinicius Faustino Lima; MOREIRA, Danilo José Silva; DA FONSECA, Juliana Brito; VASCONCELOS, Suzana Dos Santos; ROSSI, Karoline; LINHARES, Murilo Da Silva; BEZERRA, Rodolpho Montenegro; FERREIRA, Elane De Nazaré Magno. Arritmias Cardíacas no Contexto da Pandemia da COVID-19: Uma Revisão Integrativa da Literatura / Cardiac Arrhythmias in the COVID-19 Pandemic Context: An Integrative Literature Review. **Brazilian Journal of Health Review**, v. 4, n. 3, p. 12937–12958, 14 jun. 2021. DOI: <https://doi.org/10.34119/bjhrv4n3-252>. Acesso em: 14 ago. 2023.
- ELOMED. MP-IoT. 2023. Disponível em: <https://www.elomed.com.br/postagens/medidor-de-multiparametros-clinicos-finep/>. Acesso em: 26 fev. 2024.
- FAN, Xiaolong; GONG, Maoguo; XIE, Yu; JIANG, Fenlong; LI, Hao. Structured self-attention architecture for graph-level representation learning. **Pattern Recognition**, v. 100, p. 107084, abr. 2020. DOI: <https://doi.org/10.1016/j.patcog.2019.107084>. Acesso em: 19 out. 2023.
- FAUST, Oliver; SHENFIELD, Alex; KAREEM, Murtadha; SAN, Tan Ru; FUJITA, Hamido; ACHARYA, U. Rajendra. Automated detection of atrial fibrillation using long short-term memory network with RR interval signals. **Computers in Biology and Medicine**, v. 102, p. 327–335, nov. 2018. DOI: <https://doi.org/10.1016/j.combiomed.2018.07.001>. Acesso em: 15 set. 2023.

FENGLER, Brian T.; BRADY, William J.; PLAUTZ, Claire U. Atrial fibrillation in the Wolff-Parkinson-White syndrome: ECG recognition and treatment in the ED. **The American Journal of Emergency Medicine**, v. 25, n. 5, p. 576–583, jun. 2007. DOI: <https://doi.org/10.1016/j.ajem.2006.10.017>. Acesso em: 15 set. 2023.

FLUKE, BIOMEDICAL. ProSim 4 Vital Sign Patient Simulator | Fluke Biomedical. 2024. Disponível em: <https://www.flukebiomedical.com/products/biomedical-test-equipment/patient-simulators/prosim-4-vital-signs-patient-simulator>. Acesso em: 20 mar. 2024.

GALLAGHER, A.C. Detection of Linear and Cubic Interpolation in JPEG Compressed Images. In: THE 2ND CANADIAN CONFERENCE ON COMPUTER AND ROBOT VISION (CRV'05), 2005. **The 2nd Canadian Conference on Computer and Robot Vision (CRV'05)** [...]. Victoria, BC, Canada: IEEE, 2005. p. 65–72. DOI: <https://doi.org/10.1109/CRV.2005.33>. Acesso em: 12 jun. 2023.

GOLDBERGER, Ary L.; AMARAL, Luis A. N.; GLASS, Leon; HAUSDORFF, Jeffrey M.; IVANOV, Plamen Ch.; MARK, Roger G.; MIETUS, Joseph E.; MOODY, George B.; PENG, Chung-Kang; STANLEY, H. Eugene. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. **Circulation**, v. 101, n. 23, 13 jun. 2000. DOI: <https://doi.org/10.1161/01.CIR.101.23.e215>. Acesso em: 14 jun. 2023.

GRECO, Luca; PERCANNELLA, Gennaro; RITROVATO, Pierluigi; TORTORELLA, Francesco; VENTO, Mario. Trends in IoT based solutions for health care: Moving AI to the edge. **Pattern Recognition Letters**, v. 135, p. 346–353, jul. 2020. DOI: <https://doi.org/10.1016/j.patrec.2020.05.016>. Acesso em: 22 out. 2023.

HE, Runnan; WANG, Kuanquan; ZHAO, Na; LIU, Yang; YUAN, Yongfeng; LI, Qince; ZHANG, Henggui. Automatic Detection of Atrial Fibrillation Based on Continuous Wavelet Transform and 2D Convolutional Neural Networks. **Frontiers in Physiology**, v. 9, p. 1206, 30 ago. 2018. DOI: <https://doi.org/10.3389/fphys.2018.01206>. Acesso em: 10

ago. 2023.

HO, Yaoshiang; WOOKEY, Samuel. The Real-World-Weight Cross-Entropy Loss Function: Modeling the Costs of Mislabeled. **IEEE Access**, v. 8, p. 4806–4813, 2020. DOI: <https://doi.org/10.1109/ACCESS.2019.2962617>. Acesso em: 22 jun. 2023.

JAGTAP, Sonal K.; UPLANE, M. D. The impact of digital filtering to ECG analysis: Butterworth filter application. In: 2012 INTERNATIONAL CONFERENCE ON COMMUNICATION, INFORMATION & COMPUTING TECHNOLOGY (ICCICT), out. 2012. **2012 International Conference on Communication, Information & Computing Technology (ICCICT)** [...]. Mumbai, India: IEEE, out. 2012. p. 1–6. DOI: <https://doi.org/10.1109/ICCICT.2012.6398145>. Acesso em: 20 mar. 2024.

KARRI, Meghana; ANNAVAPU, Chandra Sekhara Rao. A real-time embedded system to detect QRS-complex and arrhythmia classification using LSTM through hybridized features. **Expert Systems with Applications**, v. 214, p. 119221, mar. 2023. DOI: <https://doi.org/10.1016/j.eswa.2022.119221>. Acesso em: 28 ago. 2023.

KWON, Ohhwan; JEONG, Jinwoo; KIM, Hyung Bin; KWON, In Ho; PARK, Song Yi; KIM, Ji Eun; CHOI, Yuri. Electrocardiogram Sampling Frequency Range Acceptable for Heart Rate Variability Analysis. **Healthcare Informatics Research**, v. 24, n. 3, p. 198, 2018. DOI: <https://doi.org/10.4258/hir.2018.24.3.198>. Acesso em: 11 jul. 2023.

LIU, Sen; WANG, Aiguo; DENG, Xintao; YANG, Cuiwei. MGNN: A multiscale grouped convolutional neural network for efficient atrial fibrillation detection. **Computers in Biology and Medicine**, v. 148, p. 105863, set. 2022. DOI: <https://doi.org/10.1016/j.combiomed.2022.105863>.

LUZ, Eduardo José Da S.; SCHWARTZ, William Robson; CÁMARA-CHÁVEZ, Guillermo; MENOTTI, David. ECG-based heartbeat classification for arrhythmia detection: A survey. **Computer Methods and Programs in Biomedicine**, v. 127, p. 144–164, abr. 2016. DOI:

<https://doi.org/10.1016/j.cmpb.2015.12.008>. Acesso em: 1 set. 2023.

MAGGIONI, Augusto Felipe; REBONATTO, Marcelo Trindade. **Dataset with AFIB, SB and Normal ratings at 250Hz, derivation I (DI)**. Harvard Dataverse, 2023. DOI 10.7910/DVN/ZIBSUU. Disponível em: <https://dataverse.harvard.edu/citation?persistentId=doi:10.7910/DVN/ZIBSUU>. Acesso em: 22 fev. 2024.

MEEK, S.; MORRIS, Francis. ABC of clinical electrocardiography: Introduction. I--Leads, rate, rhythm, and cardiac axis. **BMJ**, v. 324, n. 7334, p. 415–418, 16 fev. 2002. DOI: <https://doi.org/10.1136/bmj.324.7334.415>. Acesso em: 8 mar. 2023.

MOHAMMADI, Mehdi; AL-FUQAHA, Ala; SOROUR, Sameh; GUIZANI, Mohsen. Deep Learning for IoT Big Data and Streaming Analytics: A Survey. **IEEE Communications Surveys & Tutorials**, v. 20, n. 4, p. 2923–2960, 2018. DOI: <https://doi.org/10.1109/COMST.2018.2844341>. Acesso em: 6 abr. 2023.

OLIVEIRA, Rafael F.; FERREIRA, Anderson A.; MOREIRA, Gladston J. P.; LUZ, Eduardo J. S. Um Método Ensemble para Classificação de Arritmias: Uma Avaliação Com Mais de 10 Mil Registros de Sinais de ECG. *In: SIMPÓSIO BRASILEIRO DE COMPUTAÇÃO APLICADA À SAÚDE*, 7 jun. 2022. **Anais do XXII Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS 2022)** [...]. Brasil: Sociedade Brasileira de Computação - SBC, 7 jun. 2022. p. 13–24. DOI: <https://doi.org/10.5753/sbcas.2022.222429>. Acesso em: 22 fev. 2024.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V.; VANDERPLAS, J.; PASSOS, A.; COURNAPEAU, D.; BRUCHER, M.; PERROT, M.; DUCHESNAY, E. Scikit-Learn. 2011. Disponível em: <https://scikit-learn.org/stable/>. Acesso em: 24 fev. 2024.

RAHUL, Jagdeep; SORA, Marpe; SHARMA, LakhanDev. Baseline correction of ECG using regression estimation method. *In: 2019 4TH INTERNATIONAL CONFERENCE ON INTERNET OF THINGS: SMART*

**INNOVATION AND USAGES (IOT-SIU)**, abr. 2019. **2019 4th International Conference on Internet of Things: Smart Innovation and Usages (IoT-SIU)** [...]. Ghaziabad, India: IEEE, abr. 2019. p. 1–5. DOI: <https://doi.org/10.1109/IoT-SIU.2019.8777622>. Acesso em: 23 fev. 2024.

REDDI, Sashank J.; KALE, Satyen; KUMAR, Sanjiv. On the Convergence of Adam and Beyond. 2019. DOI: <https://doi.org/10.48550/ARXIV.1904.09237>. Acesso em: 22 fev. 2024.

RIBEIRO, Antonio Luiz P.; DUNCAN, Bruce B.; BRANT, Luisa C. C.; LOTUFO, Paulo A.; MILL, José Geraldo; BARRETO, Sandhi M. Cardiovascular Health in Brazil: Trends and Perspectives. **Circulation**, v. 133, n. 4, p. 422–433, 26 jan. 2016. DOI: <https://doi.org/10.1161/CIRCULATIONAHA.114.008727>. Acesso em: 22 mar. 2023.

SELESNICK, I.W.; BURRUS, C.S. Generalized digital Butterworth filter design. **IEEE Transactions on Signal Processing**, v. 46, n. 6, p. 1688–1694, jun. 1998. DOI: <https://doi.org/10.1109/78.678493>. Acesso em: 7 abr. 2023.

SHERSTINSKY, Alex. Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. **Physica D: Nonlinear Phenomena**, v. 404, p. 132306, mar. 2020. DOI: <https://doi.org/10.1016/j.physd.2019.132306>. Acesso em: 2 ago. 2023.

SOADUON SIMANJUNTAK, Jonathan Eprilio; KHODRA, Masayu Leylia; TOSIMA MANULLANG, Martin Clinton. Design Methods of Detecting Atrial Fibrillation Using the Recurrent Neural Network Algorithm on the Arduino AD8232 ECG Module. **IOP Conference Series: Earth and Environmental Science**, v. 537, n. 1, p. 012022, 1 jul. 2020. DOI: <https://doi.org/10.1088/1755-1315/537/1/012022>. Acesso em: 6 set. 2023.

SRIVASTAVA, Nitishand; HINTON, Geoffrey; KRIZHEVSKY, Alex; SUTSKEVER, Ilya; SALAKHUTDINOV, Ruslan. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. **Dropout: A Simple Way to Prevent Neural Networks from Overfitting**, v. 15, n. 56, p. 1929–1958, 2014. Acesso

em: 14 set. 2023.

SURAWICZ, Borys; KNILANS, Timothy K.; CHOU, Te-Chuan. **Chou's electrocardiography in clinical practice: adult and pediatric**. 6th ed. Philadelphia, PA: Saunders/Elsevier, 2008.

VISIONNIT. eProHeath. 24 fev. 2024. Disponível em: <https://eprontuario.visionnit.com.br/app/>. Acesso em: 25 fev. 2024.

WAGNER, Patrick; STRODTHOFF, Nils; BOUSSELJOT, Ralf-Dieter; SAMEK, Wojciech; SCHAEFFTER, Tobias. **PTB-XL, a large publicly available electrocardiography dataset**. *PhysioNet*, 22 fev. 2024. DOI: <https://doi.org/10.13026/KFZX-AW45>. Acesso em: 22 fev. 2024.

WANG, Meiqi; LU, Siyuan; ZHU, Danyang; LIN, Jun; WANG, Zhongfeng. A High-Speed and Low-Complexity Architecture for Softmax Function in Deep Learning. *In: 2018 IEEE ASIA PACIFIC CONFERENCE ON CIRCUITS AND SYSTEMS (APCCAS)*, out. 2018. **2018 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS)** [...]. Chengdu: IEEE, out. 2018. p. 223–226. DOI: <https://doi.org/10.1109/APCCAS.2018.8605654>. Acesso em: 22 fev. 2024.

YING-WEN BAI; WEN-YANG CHU; CHIEN-YU CHEN; YI-TING LEE; YI-CHING TSAI; CHENG-HUNG TSAI. Adjustable 60Hz noise reduction by a notch filter for ECG signals. *In: PROCEEDINGS OF THE 21ST IEEE INSTRUMENTATION AND MEASUREMENT TECHNOLOGY CONFERENCE, 2004. Proceedings of the 21st IEEE Instrumentation and Measurement Technology Conference (IEEE Cat. No.04CH37510)* [...]. Como, Italy: IEEE, 2004. p. 1706–1711. DOI: <https://doi.org/10.1109/IMTC.2004.1351410>. Acesso em: 22 fev. 2024.

ZHENG, Jianwei; CHU, Huimin; STRUPPA, Daniele; ZHANG, Jianming; YACCOUB, Sir Magdi; EL-ASKARY, Hesham; CHANG, Anthony; EHWERHEMUEPHA, Louis; ABUDAYYEH, Islam; BARRETT, Alexander; FU, Guohua; YAO, Hai; LI, Dongbo; GUO, Hangyuan; RAKOVSKI, Cyril. Optimal Multi-Stage Arrhythmia Classification Approach. *Scientific Reports*, v. 10, n. 1, p. 2898, 19 fev. 2020. DOI: <https://doi.org/10.1038/s41598-020-59821-7>.

Acesso em: 8 jun. 2023.

ZHENG, Jianwei; GUO, Hangyuan; CHU, Huimin. A large scale 12-lead electrocardiogram database for arrhythmia study. 22 fev. 2024. Disponível em: <https://physionet.org/content/ecg-arrhythmia/1.0.0/>.

Acesso em: 22 fev. 2024.

ZHOU, Haowen; ZHU, Ruoqing; UNG, Anita; SCHATZ, Bruce. Population analysis of mortality risk: Predictive models from passive monitors using motion sensors for 100,000 UK Biobank participants. *PLOS Digital Health*, v. 1, n. 10, p. e0000045, 20 out. 2022. DOI: <https://doi.org/10.1371/journal.pdig.0000045>. Acesso em: 9 ago. 2023.

ZHU, Fei; YE, Fei; FU, Yuchen; LIU, Quan; SHEN, Bairong. Electrocardiogram generation with a bidirectional LSTM-CNN generative adversarial network. *Scientific Reports*, v. 9, n. 1, p. 6734, 1 maio 2019. DOI: <https://doi.org/10.1038/s415ANALOG DEVICES98-019-42516-z>. Acesso em: 16 ago. 2023.