

Classificação de Arritmias no Tempo e Tempo-Frequência: Uma Abordagem Baseada em Subproblemas

Reginaldo J. Silva,¹ Andréia S. Santos,² Thays A. Abreu,³ Mara L. M. Lopes⁴

UNESP, Ilha Solteira, SP

André L. C. Costa⁵

USP, Ribeirão Preto, SP

Carlos R. S. Júnior⁶

IFSP, Hortolândia, SP

Angela L. Moreno⁷

UNIFAL, Alfenas, MG

Resumo. As arritmias cardíacas são um problema comum que requer detecção precoce para um tratamento eficaz. No entanto, a identificação precisa dessas arritmias pode ser desafiadora devido às sutis diferenças na morfologia dos sinais cardíacos. O uso de algoritmos de aprendizado de máquina tem sido explorado para aprimorar essa detecção, mas enfrenta um desafio devido ao desequilíbrio na distribuição dos dados entre as diferentes classes. Desta forma, neste estudo a proposta é dividir o problema principal em dois subproblemas, com o objetivo de reduzir o impacto do desequilíbrio das classes. Além disso, foi utilizado um ponto de corte adaptativo extraído do treinamento. Simulações foram realizadas nos domínios do tempo e do tempo-frequência, revelando melhorias na sensibilidade com essa abordagem.

Palavras-chave. Reconhecimento de Padrões, Aprendizado de Máquina, Transformada de Fourier Janelada.

1 Introdução

A arritmia cardíaca é uma condição cardíaca que afeta um número significativo de pessoas em todo o mundo, estima-se que cerca de 40 milhões de indivíduos no Brasil sejam afetados por algum tipo de arritmia cardíaca [16]. Essa condição torna-se mais prevalente com o avanço da idade, tornando-se um desafio significativo de saúde pública devido ao envelhecimento populacional observado em muitos países [17]. O termo arritmia é usado para descrever um padrão de batimento cardíaco anormal que se desvia do ritmo cardíaco sinusal regular [8].

A detecção precoce e precisa das arritmias cardíacas é crucial para um tratamento eficaz, e o eletrocardiograma (ECG) é uma ferramenta comumente utilizada para esse fim [5]. Ele registra a atividade elétrica do coração, fornecendo informações essenciais para identificar problemas cardíacos, incluindo arritmias. A identificação de arritmias depende do reconhecimento de padrões específicos de ECG associados a cada tipo [12]. Esses padrões são frequentemente comparados com critérios e diretrizes padronizados, para determinar o tipo específico de arritmia [7]. No entanto, mesmo para médicos experientes, a identificação precisa com base apenas na análise do ECG pode ser um desafio [2].

¹reginaldo.silva@unesp.br

²andrea.faria@unesp.br

³thays.abreu@unesp.br

⁴mara.lopes@unesp.br

⁵alcc.biologygen@usp.br

⁶carlos9.rsj@gmail.com

⁷angela.moreno@unifal-mg.edu.br

Com o avanço das técnicas de aprendizado de máquina, tais algoritmos tem ganhado destaque para aprimorar a detecção [1]. Embora os algoritmos apresentem resultados promissores, ainda enfrentam desafios significativos. Um desses desafios é o desequilíbrio na distribuição dos dados entre as diferentes classes, o que pode prejudicar a capacidade dos algoritmos de classificação [6]. Uma abordagem frequente envolve a aplicação de técnicas de balanceamento de dados, como *oversampling* ou *undersampling* [6]. Apesar da sua ampla adoção, é essencial considerar que o emprego de tais técnicas podem influenciar a classificação de forma que se afaste de uma aplicação real.

Desta forma, este estudo explora uma abordagem alternativa para a classificação de arritmias, fragmentando o problema principal em subproblemas nos quais o desequilíbrio dos dados não exerça um impacto significativo sobre a classificação. Além disso, a proposta inclui a adaptação do ponto de corte na probabilidade, definido a partir do conjunto de treinamento e aplicando validação cruzada *k-fold*. Para avaliar a eficácia dessa estratégia, foram utilizados dados no domínio do tempo e no domínio tempo-frequência, empregando a Transformada de Fourier Janelada, também conhecida como *Short-time Fourier Transform* (STFT) [13]. Redes neurais convolucionais foram utilizadas para a classificação e os resultados comparados com a literatura.

2 Materiais e Métodos

2.1 Processamento do Sinal e Estrutura do Modelo

O conjunto de dados MIT-BIH [11] utilizado nas simulações consiste em 48 registros de ECG de 47 indivíduos distintos, cada registro com duração de trinta minutos e amostrados a uma taxa de 360Hz. Cada registro contém dois canais, que podem incluir a derivação modificada II (MLII), V1, V2, V4 ou V5, dependendo do registro. A derivação MLII foi utilizada por estar presente na maioria dos registros. Além disso, cada batimento cardíaco foi anotado independentemente por dois ou mais cardiologistas especialistas.

O conjunto de dados de arritmias do MIT-BIH foi processado usando uma série de etapas. Primeiramente, o sinal de ECG foi extraído da derivação MLII. Em seguida, o sinal foi filtrado usando um filtro *notch* para remover interferências de linha de energia elétrica. Após o filtro, os sinais foram padronizados usando z-score conforme a equação (1):

$$z = \frac{x - \mu}{\sigma}, \tag{1}$$

em que μ e σ são, respectivamente, o valor médio e o desvio padrão do sinal. Essa padronização foi realizada para garantir que os dados estejam na mesma escala, média zero e desvio um [14]. Em seguida, os picos R foram detectados usando o algoritmo XQRS da biblioteca WFDB [19]. Os batimentos cardíacos foram então segmentados em janelas de 300 pontos, sendo 100 pontos antes do pico R detectado e 200 pontos após. A Figura 1 mostra uma janela de 10s do sinal original, bem como uma amostra do sinal processado (domínio do tempo) que foi utilizado no processo de classificação das arritmias.

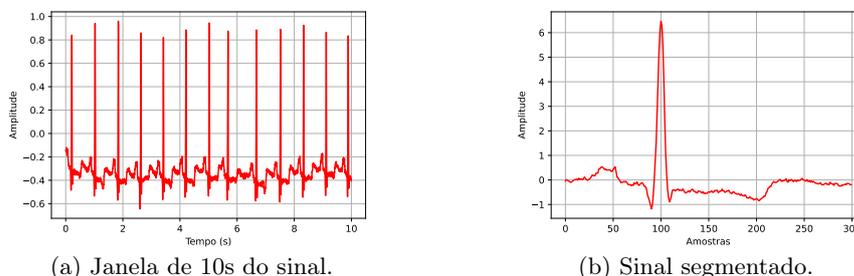
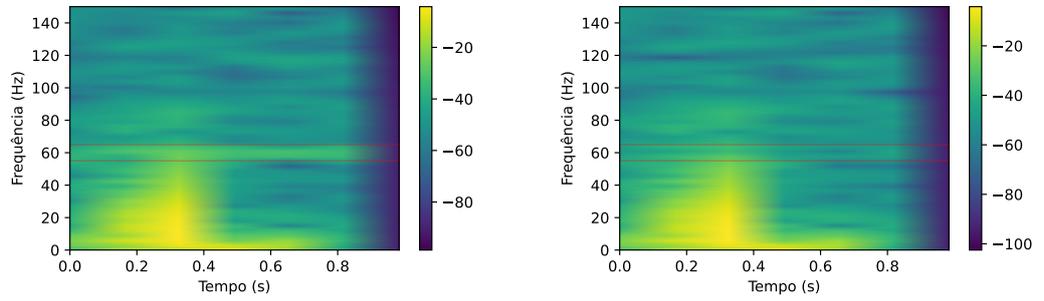


Figura 1: Exemplo de sinal de ECG. Fonte: dos autores.

Além disso, foi aplicada a STFT aos segmentos de sinal para obter representações no domínio tempo-frequência. Define-se a STFT de um sinal discreto $x[n]$ como [13]:

$$X[n, \omega] = \sum_{m=-\infty}^{\infty} x[n+m] \cdot w[m] \cdot e^{-j\omega m}, \quad (2)$$

em que $x[n]$ representa o sinal, enquanto $w[n]$ é uma janela deslizante. Essa abordagem possibilita uma análise da variação da frequência ao longo do tempo, o resultado obtido, representado por $X[n, \omega]$, é uma matriz bidimensional conhecida como espectrograma. Os cálculos foram realizados com uma janela de 118 pontos e sobreposição de 50% resultando em uma dimensão de 60×7 . A Figura 2 apresenta os espectros de um sinal, na Figura 2 (a), mostra o sinal com a interferência de 60Hz na linha de energia e a Figura 2 (b) apresenta o sinal após a aplicação do filtro *notch* para remoção dessa frequência.



(a) Sinal segmentado sem filtrar.

(b) Sinal segmentado filtrado.

Figura 2: Espectro de sinal de ECG segmentado. Fonte: dos autores.

Após a obtenção dos espectros com dimensão de 60×7 , foi realizada a aplicação da interpolação de Lanczos 2D para um redimensionamento de 60×60 . Essa interpolação é uma técnica comumente utilizada para redimensionamento de imagens que preserva melhor os detalhes e reduz artefatos em comparação com outros métodos de interpolação [9].

A interpolação de Lanczos 2D é realizada por meio da operação de convolução linear entre os valores originais $s_{i,j}$ e uma função de janela de Lanczos $L(x)$ [9]. A fórmula da interpolação de Lanczos 2D é dada pela equação (3):

$$S(x, y) = \sum_{i=\lfloor x \rfloor - a + 1}^{\lfloor x \rfloor + a} \sum_{j=\lfloor y \rfloor - a + 1}^{\lfloor y \rfloor + a} s_{i,j} \cdot L(x - i) \cdot L(y - j), \quad (3)$$

em que $S(x, y)$ representa o valor interpolado na posição (x, y) , $s_{i,j}$ são os valores originais, $L(x)$ é a função de janela de Lanczos definida pela equação (4), o parâmetro a determina o comprimento da janela.

$$L(x) = \begin{cases} 1, & x = 0, \\ \frac{a \operatorname{seno}(\pi x) \operatorname{seno}\left(\frac{\pi x}{a}\right)}{\pi^2 x^2} & \text{se } 0 < |x| < a, \\ 0 & \text{caso contrário.} \end{cases} \quad (4)$$

Por fim, as 16 classes do conjunto original foram agrupadas em cinco categorias, seguindo as diretrizes estabelecidas pela *Association for the Advancement of Medical Instrumentation* (AAMI) EC57 [3]. A quantidade de amostras em cada classe pode ser visto na Tabela 1.

Tabela 1: Quantidade de amostras em cada classe.

Classe	Normal (0)	SVEB (1)	VEB (2)	F (3)	Q (4)
Quantidade	87404	2683	3564	593	1286

SVEB: Batimento ectópico supraventricular, VEB: Batimento ectópico ventricular, F: Batimento de fusão, Q: Batimento desconhecido

Para mitigar o efeito do desbalanceamento dos dados durante a classificação, o problema foi dividido em dois subproblemas, nos quais o desbalanceamento foi reduzido. O primeiro subproblema envolveu a classificação de pacientes em duas categorias: normais e anormais, agrupando todas as classes de arritmias (SVEB, VEB, F e Q da Tabela 1). Por sua vez, o segundo subproblema focou na classificação das quatro classes de arritmias, eliminando a influência que a alta quantidade de dados normais poderia ter sobre a classificação.

A arquitetura do modelo utilizado para as simulações pode ser visto na Figura 3. O modelo foi treinado utilizando o otimizador Adam com taxa de aprendizado de 0,001, lote de 128 amostras e 100 épocas.

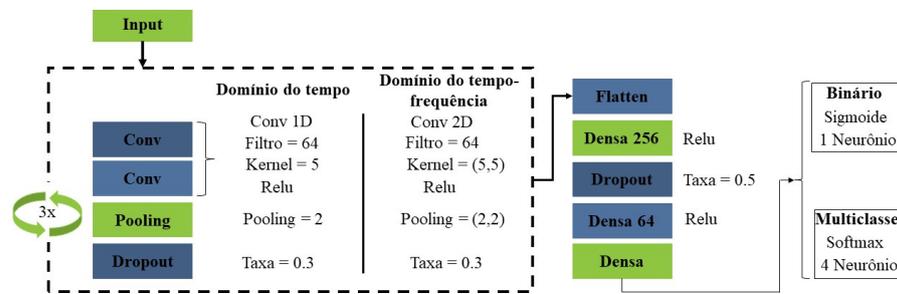


Figura 3: Arquitetura do modelo. Fonte: dos autores.

O método *Hold-out* foi utilizado para dividir o conjunto de dados em treino e teste com uma proporção de 70–30. Em seguida, o conjunto de treinamento foi dividido novamente utilizando *k-fold* com $k = 2$, dentro deste conjunto de treinamento e validação foi extraído o ponto de corte a partir do índice Youden aplicado a curva ROC que foi posteriormente utilizado no teste. Essa abordagem também colabora para classificação mesmo diante de classes desbalanceadas, visto que o índice Youden na curva ROC busca o ponto de corte que maximiza tanto a sensibilidade quanto a especificidade.

3 Resultados Computacionais

A Figura 4 apresenta as curvas ROC para cada subproblema tanto no domínio do tempo quanto no tempo-frequência. Analisando os resultados é possível observar que o modelo obteve desempenho satisfatório em ambos os domínios, com AUC-ROC variando entre 0,9949 e 0,9972. Além disso, observa-se que no domínio tempo-frequência, os resultados foram superiores aos obtidos no domínio do tempo, indicando que a inclusão de informações sobre a frequência do sinal contribuiu para melhorar o desempenho do modelo.

Na classificação das arritmias no subproblema 2, nota-se que o modelo teve certa dificuldade em classificar a classe 3 que corresponde a batimentos de fusão tanto no domínio do tempo quanto tempo-frequência. Essa dificuldade pode ser comparada com resultados anteriores encontrados em outros estudos [2, 18], evidenciando um desafio recorrente na classificação desses tipos específicos de batimentos.

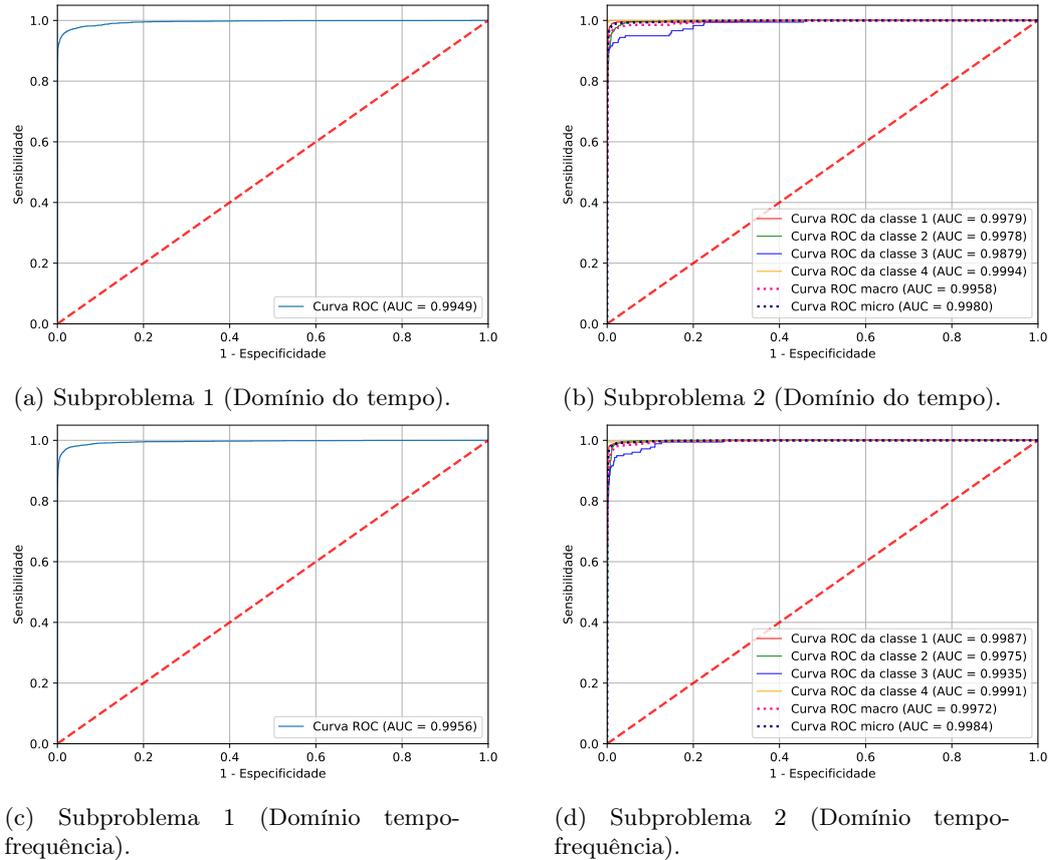


Figura 4: Curva ROC dos resultados obtidos. Fonte: dos autores.

A Tabela 2 apresenta uma comparação entre os resultados obtidos neste estudo e alguns dos trabalhos disponíveis na literatura.

Tabela 2: Comparativo do resultados com a literatura.

Autor	Domínio	Tipo	ACC	Se	Sp	AUC-ROC
Este	Tempo	Binário	0,9901	0,9709	0,9990	0,9949
Estudo	Tempo	Multiclasse	0,9836	0,9610	0,9933	0,9958
	Tempo-Frequência	Binário	0,9906	0,9651	0,9973	0,9956
	Tempo-Frequência	Multiclasse	0,9778	0,9577	0,9916	0,9972
[10]	Tempo-Frequência	Multiclasse	0,9450	0,7030	–	–
[18]	Tempo	Multiclasse	0,9766	0,5099	0,9320	–
[15]	Tempo	Binário	0,9600	0,8300	0,9800	–
[2]	Tempo	Multiclasse	0,9900	0,9400	0,9900	$\approx 1,0000$
[4]	Tempo-Frequência	Multiclasse	0,9960	0,9580	–	–

ACC: Acurácia, Se : Sensibilidade, Sp : Especificidade

Comparando esses resultados observa-se que para a classificação binária, este estudo superou em termos de acurácia, sensibilidade e especificidade os resultados obtidos em [15]. Por outro lado, comparando a classificação multiclasse, nota-se que os resultados deste estudo ainda se destacam, alcançando resultados superiores aos obtidos por [2, 10, 18]. Vale ressaltar que o valor de AUC

apresentado em [2] foi aproximado, não representando a verdadeira precisão do resultado obtido. No entanto, ao se considerar a sensibilidade e especificidade, os resultados obtidos neste trabalho prevalecem superiores.

4 Considerações Finais

Este estudo apresenta o uso de redes neurais convolucionais para a classificação de arritmias no domínio do tempo e tempo-frequência, uma abordagem simples foi utilizada para reduzir o impacto do desbalanceamento das classes que consistiu na subdivisão do problema em uma tarefa binária (Normal vs. Anormal) e outra de classificação multiclasse, abrangendo quatro tipos distintos de arritmias. Os resultados demonstraram a eficácia dessa abordagem, alcançando elevadas taxas de acurácia, sensibilidade e especificidade para ambos os subproblemas e domínios. Além disso, as curvas ROC exibiram valores notáveis de AUC-ROC, confirmando a capacidade da metodologia utilizada. Essa técnica de subdivisão pode ser especialmente útil ao utilizar algoritmos de treinamento on-line, minimizando o impacto que os dados normais podem ter sobre classes menos representadas.

Esses resultados mostram que é possível obter um desempenho sólido, ao dividir o problema, sem comprometer a qualidade. Em pesquisas futuras, pretende-se abordar o desequilíbrio diretamente no modelo, introduzindo um viés que equilibre a tendência do modelo de se concentrar na classe majoritária. Isso tem o potencial de tornar algoritmos de detecção mais robustos e confiáveis. Além de testar essa abordagem em algoritmos de treinamento contínuo (on-line).

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 pelo auxílio financeiro.

Referências

- [1] U. R. Acharya et al. “Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network”. Em: **Information Sciences** 405 (2017), pp. 81–90. DOI: [10.1016/j.ins.2017.04.012](https://doi.org/10.1016/j.ins.2017.04.012).
- [2] A. A. Ahmed et al. “Classifying Cardiac Arrhythmia from ECG Signal Using 1D CNN Deep Learning Model”. Em: **Mathematics** 11.3 (2023). DOI: [10.3390/math11030562](https://doi.org/10.3390/math11030562).
- [3] ANSI/AAMI EC57. **Testing and Reporting Performance Results of Cardiac Rhythm and ST Segment Measurement Algorithms**. Ed. por American National Standards Institute (ANSI). Association for the Advancement of Medical Instrumentation (AAMI), 1998.
- [4] Y. Han et al. “Novel Transformation Deep Learning Model for Electrocardiogram Classification and Arrhythmia Detection using Edge Computing”. Em: **Journal of Grid Computing** 22.1 (2023), p. 7. DOI: [10.1007/s10723-023-09717-3](https://doi.org/10.1007/s10723-023-09717-3).
- [5] S. P. Karunathilake e G. U. Ganegoda. “Secondary Prevention of Cardiovascular Diseases and Application of Technology for Early Diagnosis”. Em: **BioMed Research International** 2018 (2018), p. 5767864. DOI: [10.1155/2018/5767864](https://doi.org/10.1155/2018/5767864).

- [6] V. López et al. “An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics”. Em: **Information Sciences** 250 (2013), pp. 113–141. DOI: [10.1016/j.ins.2013.07.007](https://doi.org/10.1016/j.ins.2013.07.007).
- [7] A. Lorga et al. “Diretrizes para Avaliação e Tratamento de Pacientes com Arritmias Cardíacas”. Em: **Arquivos Brasileiros de Cardiologia** 79 (2002), pp. 1–50. DOI: [10.1590/S0066-782X2002001900001](https://doi.org/10.1590/S0066-782X2002001900001).
- [8] S. Ma et al. “An effective data enhancement method for classification of ECG arrhythmia”. Em: **Measurement** 203 (2022), p. 111978. DOI: [10.1016/j.measurement.2022.111978](https://doi.org/10.1016/j.measurement.2022.111978).
- [9] B. N. Madhukar e R. Narendra. “Lanczos Resampling for the Digital Processing of Remotely Sensed Images”. Em: **Proceedings of International Conference on VLSI, Communication, Advanced Devices, Signals & Systems and Networking**. 2013, pp. 403–411.
- [10] V. Mondéjar-Guerra et al. “Heartbeat classification fusing temporal and morphological information of ECGs via ensemble of classifiers”. Em: **Biomedical Signal Processing and Control** 47 (2019), pp. 41–48. DOI: [10.1016/j.bspc.2018.08.007](https://doi.org/10.1016/j.bspc.2018.08.007).
- [11] G. B. Moody e R. G. Mark. “The impact of the MIT-BIH Arrhythmia Database”. Em: **IEEE Engineering in Medicine and Biology Magazine** 20.3 (2001), pp. 45–50. DOI: [10.1109/51.932724](https://doi.org/10.1109/51.932724).
- [12] K. A. K. Niazi et al. “Identifying best feature subset for cardiac arrhythmia classification”. Em: **Science and Information Conference**. 2015, pp. 494–499. DOI: [10.1109/SAI.2015.7237188](https://doi.org/10.1109/SAI.2015.7237188).
- [13] A. V. Oppenheim e R. W. Schaffer. **Discrete-Time Signal Processing**. Pearson Education, 2011.
- [14] G. K. Panicker et al. “Z-Score for Benchmarking Reader Competence in a Central ECG Laboratory”. Em: **Annals of Noninvasive Electrocardiology** 14.1 (2009), pp. 19–25. DOI: [10.1111/j.1542-474X.2008.00269.x](https://doi.org/10.1111/j.1542-474X.2008.00269.x).
- [15] G. Sivapalan et al. “ANNet: A Lightweight Neural Network for ECG Anomaly Detection in IoT Edge Sensors”. Em: **IEEE Transactions on Biomedical Circuits and Systems** 16.1 (2022), pp. 24–35. DOI: [10.1109/TBCAS.2021.3137646](https://doi.org/10.1109/TBCAS.2021.3137646).
- [16] SOBRAC. **Arritmias cardíacas: 10 informações úteis para seu coração bater no ritmo certo**. Online. Acessado em 07/02/2024, <https://sobrac.org/publico-geral/?p=4463>.
- [17] United Nations - UN. **World Population Aging 2017**. Online. Acessado em 08/02/2024, https://www.un.org/en/development/desa/population/publications/pdf/ageing/WPA2017_Highlights.pdf. 2017.
- [18] Y. Xia, Y. Xiong e K. Wang. “A transformer model blended with CNN and denoising autoencoder for inter-patient ECG arrhythmia classification”. Em: **Biomedical Signal Processing and Control** 86 (2023), p. 105271.
- [19] C. Xie et al. **Waveform Database Software Package (WFDB) for Python**. Online. Acessado em 22/02/2024, <https://doi.org/10.13026/9njx-6322>. 2022.