

# Medidas de Entropia e Inteligência Artificial para a Detecção de Arritmias Cardíacas em Sinais de ECG

André R. Coimbra<sup>1,2</sup>, Ana Cristina S. Rebelo<sup>3</sup>, Maria Ribeiro<sup>1,3,4</sup>,  
Antonio Oliveira-Jr<sup>1,5</sup>

<sup>1</sup>Instituto de Informática – Universidade Federal de Goiás (UFG)  
Goiânia, Goiás – Brasil

<sup>2</sup>Instituto Federal de Educação, Ciência e Tecnologia de Goiás (IFG)  
Goiânia, Goiás – Brasil

<sup>3</sup>Faculdade de Medicina – Universidade Federal de Goiás (UFG)  
Goiânia, Goiás – Brasil

<sup>4</sup>Instituto de Eng. de Sistemas e Computadores, Tecnologia e Ciência (INESC TEC)  
Porto – Portugal

<sup>5</sup>Fraunhofer Portugal AICOS  
Porto – Portugal

andre.coimbra@ifg.edu.br, {ana\_rebelo, rosarioribeiro, antoniojr}@ufg.br

**Abstract.** *Cardiac arrhythmia is a common cardiovascular condition characterized by irregular heart rhythms. This study evaluates entropy-based features extracted from short-duration Electrocardiogram (ECG) signals for the automatic detection of arrhythmias using Artificial Neural Networks (ANNs) in binary and multiclass settings. Five classical entropy measures were evaluated, individually and in pairs, in addition to Recurrence Microstate Entropy (RMEn). Our findings reveal that the combination of Sample Entropy (SampEn) and Singular Value Decomposition Entropy (SVDEn) achieved performance comparable to RMEn, outperforming it in 4 out of 6 binary classification scenarios and reaching an accuracy of  $77.6\% \pm 2.1\%$  in the multiclass classification task.*

**Resumo.** *A arritmia cardíaca é uma condição clínica frequente, caracterizada por alterações no ritmo cardíaco. Este trabalho investigou o uso de medidas de entropia extraídas de sinais de Eletrocardiograma (ECG) de curta duração para a detecção automática de arritmias utilizando Redes Neurais Artificiais (ANNs), em cenários de classificação binária e multiclasse. Foram avaliadas cinco medidas clássicas de entropia, individualmente e em pares, e a entropia de Microestados de Recorrência (RMEn). A combinação da Entropia Amostral (SampEn) com a baseada na Decomposição em Valores Singulares (SVDEn) apresentou desempenho equivalente ao da RMEn, superando-a em 4 dos 6 cenários de classificação binária e alcançando acurácia de  $77,6\% \pm 2,1\%$  na multiclasse.*

## 1. Introdução

As doenças cardiovasculares permanecem como a principal causa de mortalidade global, totalizando aproximadamente 20,5 milhões de óbitos em 2021, o que representa cerca de

um terço de todas as mortes registradas no mundo [Lindstrom et al. 2022]. Entre os diversos distúrbios associados às doenças cardiovasculares, destacam-se as arritmias cardíacas, caracterizadas por alterações no ritmo normal, chamado de ritmo sinusal (SR), que comprometem a eficiência do bombeamento sanguíneo [Sridhar et al. 2024]. Devido à alta frequência com que ocorrem, a detecção precoce é essencial para reduzir riscos, prevenir eventos cardiovasculares e aumentar as chances de sobrevivência [Schnabel et al. 2023].

Nesse contexto, o Eletrocardiograma (ECG) continua sendo a principal ferramenta para o monitoramento da atividade elétrica cardíaca e para o diagnóstico de arritmias, permitindo a identificação de padrões anormais de forma precisa, não invasiva e acessível [Sridhar et al. 2024]. Com o avanço das tecnologias móveis de saúde, dispositivos vestíveis e monitores portáteis passaram a registrar sinais de ECG em tempo real, ampliando a monitorização para além do ambiente clínico [Schnabel et al. 2023].

Tradicionalmente, a interpretação de sinais de ECG baseia-se em métodos lineares e na inspeção visual realizada por especialistas [Rahul and Sharma 2025], contudo esses métodos apresentam limitações por assumirem linearidade em sinais intrinsecamente complexos e não estacionários, além de estarem sujeitos à variabilidade interobservador e a potenciais erros humanos [Sridhar et al. 2021].

A crescente disponibilidade de dados tem impulsionado o desenvolvimento de soluções baseadas em Inteligência Artificial (IA) para apoiar decisões médicas e aumentar a consistência diagnóstica. Nesse cenário, abordagens multimodais que combinam sinais como ECG e fotopletimografia têm ganhando destaque por aumentar a robustez diagnóstica e melhorar o desempenho na detecção de arritmias [Rathnayake et al. 2026]. Entretanto, tais abordagens ainda necessitam ser mais exploradas e validadas em diferentes contextos clínicos para ampla adoção [Rahul and Sharma 2025].

Paralelamente, medidas de complexidade não linear, como medidas de entropia, têm se destacado pela capacidade de capturar padrões sutis e dinâmicas irregulares associadas à variabilidade da frequência cardíaca [Henriques et al. 2020]. Nesse contexto, tais medidas têm sido empregadas na detecção de arritmias cardíacas, evidenciando seu potencial na análise de sinais de ECG [Liu et al. 2018].

Em [Asgharzadeh-Bonab et al. 2020], a utilização da Entropia Espectral (SpecEn) em redes neurais convolucionais, demonstrou elevada capacidade de separação entre cinco diferentes tipos de ritmos cardíacos, incluindo o ritmo normal. Em [Śmigiel et al. 2021], cujo objetivo foi avaliar diferentes arquiteturas de redes neurais profundas, observou-se que a incorporação de medidas de entropia, como a Entropia de Shannon, Aproximada (ApEn), Amostral (SampEn), de Permutação (PermEn), baseada na Decomposição em Valores Singulares (SVDEn), entre outras, elevou significativamente o desempenho dos modelos, sobretudo em cenários de classificação multiclasse.

A Entropia de Microestados de Recorrência (RMEn), originalmente proposta em [Corso et al. 2018] e adaptada em [Prado et al. 2020], apresenta-se como uma alternativa para mensurar a complexidade de séries temporais, a partir da análise de padrões recorrentes em gráficos de recorrência com limiares adaptativos. Em [Boaretto et al. 2024], foi proposto o uso da RMEn em sinais de ECG para gerar vetores de características para diferentes classificadores, obtendo resultados promissores na distinção de ritmos cardíacos. Entretanto, o estudo limitou-se à avaliação dessa única medida de entropia.

Assim, este trabalho realiza uma análise comparativa de cinco medidas clássicas de entropia (PermEn, SampEn, de Shannon, SpecEn e SVDEn) em relação à RMEn para a detecção de arritmias cardíacas a partir de sinais de ECG. As medidas clássicas de entropia são avaliadas individualmente e em pares como vetores de características para Redes Neurais Artificiais (ANNs), considerando cenários de classificação binária e multiclasse.

As principais contribuições deste artigo incluem: (i) uma análise comparativa sistemática de seis medidas de entropia, incluindo a RMEn, em cenários de classificação binária e multiclasse utilizando ANNs; (ii) a avaliação da combinação em pares de medidas clássicas de entropia; e (iii) a evidência empírica de que o par SampEn e SVDEn alcança desempenho equivalente ao da RMEn. Adicionalmente, o código-fonte do estudo é disponibilizado publicamente<sup>1</sup> para garantir reprodutibilidade e apoiar novas pesquisas.

O restante deste artigo está organizado da seguinte forma: a Seção 2 descreve a metodologia proposta e a base de dados utilizada; a Seção 3 discute os resultados experimentais obtidos; e a Seção 4 conclui e traz as perspectivas para trabalhos futuros.

## 2. Metodologia

Esta seção descreve a base de dados, as medidas de entropia utilizadas para extração de características, a arquitetura das ANNs e o procedimento de avaliação. A abordagem proposta, ilustrada na Figura 1, pode ser resumida em três etapas principais: (i) cálculo das medidas de entropia para extração de características; (ii) classificação binária e multiclasse dos ritmos cardíacos com ANNs; e (iii) avaliação de desempenho.

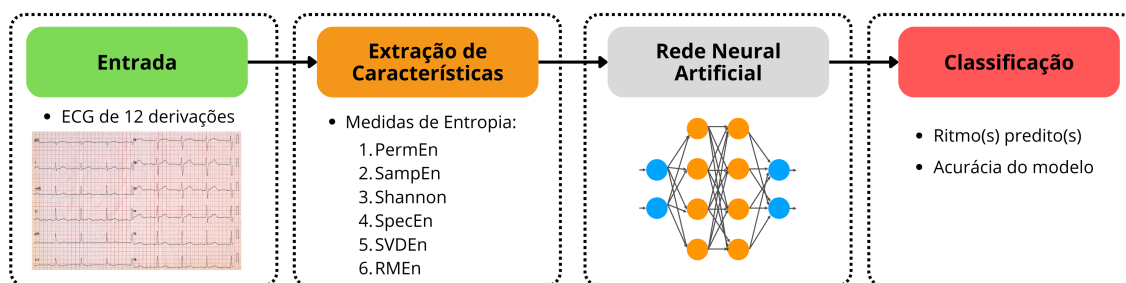


Figura 1. Diagrama da abordagem proposta para a detecção de arritmias.

### 2.1. Base de Dados

Neste trabalho, utilizou-se uma base de dados pública composta por sinais de ECG de 12 derivações, com duração de 10 segundos e frequência de amostragem de 500 Hz, totalizando 5.000 amostras por derivação [Zheng et al. 2020]. O conjunto inclui registros de 10.646 indivíduos, sendo 5.956 homens e 4.690 mulheres, distribuídos em 11 classes de ritmos cardíacos, anotadas por especialistas, conforme apresentado na Tabela 1. Observa-se que cerca de 17% dos pacientes apresentam SR e 83% exibem pelo menos uma anormalidade.

A base de dados, além dos sinais brutos, também disponibiliza uma versão com os sinais de ECG previamente processados por meio de técnicas de filtragem, incluindo filtro passa-baixa de Butterworth, suavização por regressão ponderada local e médias

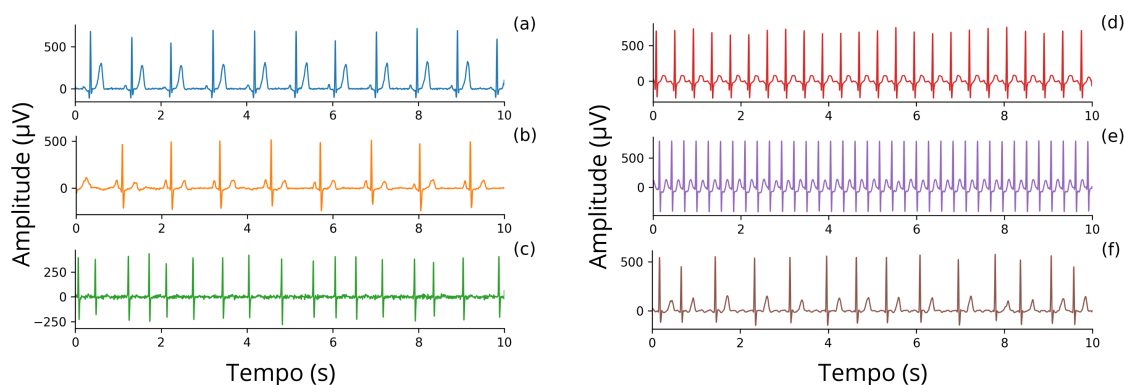
<sup>1</sup>Disponível em: <https://github.com/andrecoimbra/ecg-classification-entropy>

**Tabela 1. Distribuição dos ritmos cardíacos na base de dados [Zheng et al. 2020].**

Nome do ritmo	Acrônimo	Participantes (%)
Ritmo Sinusal	SR	1.826 (17,15)
Bradicardia Sinusal	SB	3.889 (36,53)
Fibrilação Atrial	AFIB	1.780 (16,72)
Taquicardia (Taq.) Sinusal	ST	1.568 (14,73)
Taq. Supraventricular	SVT	587 (5,51)
Flutter Atrial	AF	445 (4,18)
Irregularidade Sinusal	SI	399 (3,75)
Taq. Atrial	AT	121 (1,14)
Taq. de Reentrada Nodal Atrioventricular	AVNRT	16 (0,15)
Taq. de Reentrada Atrioventricular	AVRT	8 (0,07)
Ritmo Errante do Átrio Sinusal	SAAWR	7 (0,07)
<b>Total</b>		<b>10.646 (100)</b>

não locais, conforme descrito em [Zheng et al. 2020]. Seguindo a metodologia adotada em [Boaretto et al. 2024], este trabalho utilizou apenas os sinais pré-processados, tendo sido excluídos 58 registros em função da detecção de dados corrompidos.

A Figura 2 (a–f) apresenta exemplos da primeira derivação dos registros da base de dados, contemplando os seis ritmos cardíacos mais frequentes. Portanto, verifica-se o desafio dessa análise automática de sinais de ECG, uma vez que as séries temporais possuem curta duração, abrangendo apenas alguns batimentos por participante.



**Figura 2. Sinais típicos da primeira derivação dos registros de ECG, considerando os 6 ritmos mais frequentes na base de dados: (a) SR, Ritmo Sinusal; (b) SB, Bradicardia Sinusal; (c) AFIB, Fibrilação Atrial; (d) ST, Taquicardia Sinusal; (e) SVT, Taquicardia Supraventricular; (f) AF, Flutter Atrial.**

## 2.2. Extração de Características com Medidas de Entropia

Ao trabalhar com sinais de ECG, existem diferentes formas de extrair características para serem utilizadas como entrada em ANNs. No contexto da variabilidade da frequência cardíaca, considerando a dinâmica não linear, além das medidas de entropia, autores utilizam a Análise de Flutuações Sem Tendências (DFA) [Jiang and Wang 2024], a Análise de Quantificação de Recorrência (RQA) [Mandal et al. 2025]. Sob o aspecto clínico,

podem ser explorados parâmetros associados ao complexo PQRST (a onda P indica a despolarização atrial, o complexo QRS é responsável pela despolarização ventricular e a onda T pela repolarização ventricular) e os intervalos RR (tempo decorrido entre duas ondas R sucessivas) [Neha et al. 2021]. No domínio da frequência, são realizadas análises espectrais da série de intervalos RR, obtendo-se componentes de frequência que permitem a avaliação do balanço autonômico cardíaco [Kim et al. 2022].

Neste trabalho, a extração de características considerou cinco medidas clássicas de entropia e a RMEn, aplicadas às 12 derivações dos sinais de ECG que passaram pelo processo de normalização min–max, garantindo que as séries estivessem entre o intervalo 0 e 1. Assim, as medidas calculadas foram:

- **PermEn (Entropia de Permutação):** mede as relações de ordem entre as amostras de ECG, quantificando a regularidade e previsibilidade do sinal [Bandt and Pompe 2002];
- **SampEn (Entropia Amostral):** uma modificação da Entropia Aproximada, que mede a regularidade da série, desenvolvida com o objetivo de superar a limitação da dependência do tamanho da amostra [Richman and Moorman 2000];
- **Entropia de Shannon:** expressa a incerteza associada à distribuição dos valores do sinal, portanto uma medida da dispersão dos dados [Shannon 1948];
- **SpecEn (Entropia Espectral):** quantifica a complexidade do sinal com base na distribuição de sua densidade espectral de potência, refletindo a dispersão de energia entre as frequências [Inouye et al. 1991];
- **SVDEn (Entropia por Decomposição em Valores Singulares):** utiliza a decomposição em valores singulares para quantificar a complexidade estrutural do sinal, permitindo distinguir sinais com diferentes níveis de organização interna e sendo sensível à distribuição de energia entre os componentes singulares;
- **RMEn (Entropia de Microestados de Recorrência):** quantifica a complexidade do ECG a partir da distribuição de padrões locais extraídos do gráfico de recorrência, avaliados em função de um limiar de recorrência  $\varepsilon$ . O limiar ótimo  $\varepsilon_0$  é determinado automaticamente pela maximização da entropia dos microestados, resultando no par  $(\hat{S}_{\max}, \varepsilon_0)$  [Boaretto et al. 2024].

### 2.3. Classificação com Redes Neurais Artificiais

Em função do foco na avaliação da capacidade discriminativa das medidas de entropia na extração de características, optou-se pela utilização de ANNs do tipo *feedforward*, em vez de arquiteturas modernas de DL, permitindo uma análise mais controlada do impacto de cada medida na tarefa de classificação. Foram considerados dois cenários:

- a) *classificação binária:* entre o SR (ritmo normal) e, separadamente os outros seis ritmos mais frequentes na base de dados: SB, AFIB, ST, SVT, AF e SI; e
- b) *classificação multiclasse:* abrangendo os quatro ritmos mais frequentes na base de dados: SR, SB, AFIB e ST.

Na classificação binária, utilizou-se uma rede com duas camadas ocultas com 64 neurônios, ativação ReLU, normalização por lote, *dropout* de 50% e saída sigmoide, treinada com função de perda *binary crossentropy*. Para a classificação multiclasse, a saída foi adaptada para ativação *softmax* e perda *categorical crossentropy*, mantendo-se a mesma estrutura, com *dropout* de 30%. Os parâmetros da rede foram padronizados para todas as medidas de entropia visando garantir comparabilidade entre os resultados.

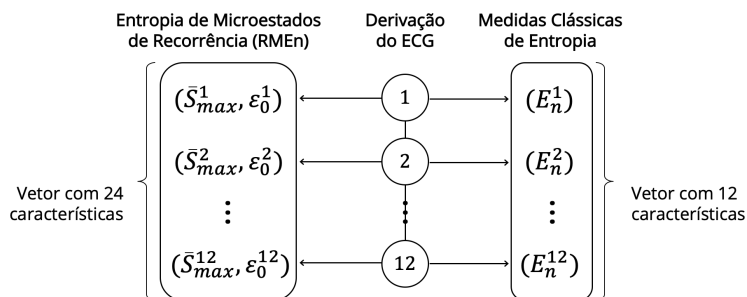
## 2.4. Avaliação de Desempenho

A avaliação dos modelos utilizou a validação cruzada em 10 dobras ( $k = 10$ ), utilizando 90% dos dados para treinamento e 10% para teste. A acurácia média foi adotada como métrica principal de desempenho, representando a proporção de classificações corretas em todas as dobras.

## 3. Resultados e Discussão

Neste estudo, a partir dos sinais de ECG, foram calculadas cinco medidas clássicas de entropia: PermEn (ordem: 3, atraso: 1), SampEn (ordem: 2, tolerância:  $0,4 \times$  desvio padrão do sinal), Shannon (utilizando um histograma de 20 classes), SpecEn (método de Welch e considerando a frequência de amostragem de 500 Hz) e a SVDEn (ordem: 3, atraso: 1). Além disso, a RMEn foi calculada considerando os mesmos parâmetros detalhados em [Boaretto et al. 2024].

Cada série de ECG possuía dimensão  $5.000 \times 12$  (5.000 amostras por derivação). Conforme ilustrado na Figura 3, cada medida clássica de entropia gerou, para cada sinal de ECG, um vetor de características de dimensão 12, em que  $E_n^k$  denota o valor da  $n$ -ésima entropia na  $k$ -ésima derivação ( $n = 1, \dots, 5$ ;  $k = 1, \dots, 12$ ). Já a RMEn resultou em vetores de dimensão 24, uma vez que, para cada derivação, são extraídos o valor máximo de entropia e o respectivo limiar ótimo ( $\bar{S}_{max}, \varepsilon_0$ ). Portanto, para permitir uma comparação mais justa entre as abordagens, propôs-se a combinação das medidas clássicas de entropia em pares, visando uniformizar a dimensão dos vetores de características.



**Figura 3. Dimensão dos vetores de características. As medidas clássicas de entropia geram vetores de dimensão 12 ( $E_n^k$ ), enquanto a RMEn produz vetores de dimensão 24, formados pelos pares  $(\bar{S}_{max}^k, \varepsilon_0^k)$  por derivação.**

O código foi desenvolvido em *Python*, utilizando as bibliotecas *Keras* para a implementação das ANNs, e *Antropy* e *SciPy* para o cálculo das medidas clássicas de entropia. A seguir, são apresentados e discutidos os resultados obtidos neste trabalho.

### 3.1. Classificação Binária

Conforme mencionado anteriormente, a classificação binária levou em consideração o SR e os seis ritmos cardíacos alterados mais frequentes na base de dados: SB, AFIB, ST, SVT, AF e SI. A Tabela 2 apresenta os valores de acurácia média e desvio padrão obtidos com a aplicação individual das cinco medidas clássicas de entropia e da RMEn, sendo que os maiores valores para cada par de ritmos cardíacos encontram-se destacados em negrito. De forma geral, nesse cenário, a RMEn apresentou o melhor desempenho, alcançando as maiores acurácias na maioria dos casos avaliados.

**Tabela 2. Acurácia da Classificação Binária com medidas de entropia individuais.**

Ritmos	Acurácia (%) por medida de entropia [ $k = 10$ ]					
	PermEn	SampEn	Shannon	SpecEn	SVDEn	RMEEn
SR × SB	69,5 ± 3,2	84,4 ± 1,6	72,1 ± 1,5	67,8 ± 2,4	84,4 ± 1,5	<b>87,7 ± 1,0</b>
SR × AFIB	76,7 ± 2,2	82,9 ± 2,5	72,3 ± 1,5	79,1 ± 1,8	68,6 ± 2,5	<b>84,4 ± 2,2</b>
SR × ST	66,8 ± 3,2	84,1 ± 2,2	74,4 ± 2,3	72,3 ± 2,3	80,5 ± 3,5	<b>89,8 ± 2,3</b>
SR × SVT	84,2 ± 1,3	95,9 ± 1,4	94,3 ± 1,1	95,1 ± 1,2	93,6 ± 1,8	<b>97,3 ± 0,6</b>
SR × AF	88,2 ± 2,7	<b>91,9 ± 2,1</b>	88,7 ± 1,9	82,9 ± 2,6	84,9 ± 1,9	91,7 ± 0,8
SR × SI	82,4 ± 2,1	81,4 ± 2,0	80,1 ± 3,1	<b>84,0 ± 1,8</b>	81,3 ± 2,9	80,8 ± 2,4

Entre as medidas clássicas de entropia, a SampEn apresentou acurácias superiores a 80% em todos os casos, destacando-se como a melhor medida individual no par SR×AF. Enquanto o SR é caracterizado por ondas P bem definidas, complexos QRS regulares e frequência cardíaca entre 60 e 100 batimentos por minuto (bpm), o AF (Flutter Atrial) ocorre quando o coração bate mais rápido que o normal e de forma pouco regular [Prystowsky et al. 2020], resultando em variações temporais no ECG, que são detectadas pela SampEn, por ser uma medida sensível à regularidade temporal do sinal.

A SpecEn apresentou o melhor desempenho no par SR×SI, um dos cenários mais desafiadores em termos de separabilidade, uma vez que a SI (irregularidade sinusal) difere do SR basicamente pela variabilidade dos intervalos RR [Prystowsky et al. 2020]. Este resultado reforça a capacidade da SpecEn de capturar alterações na estrutura espectral do sinal, mesmo quando a organização temporal global é mantida.

No par SR×SVT, quase todas as medidas alcançaram acurácias superiores a 93%, refletindo a maior separabilidade entre estes ritmos. Embora a SVT (Taquicardia Supraventricular) seja descrita pela aceleração súbita do coração com ritmo relativamente regular [Prystowsky et al. 2020], neste estudo as medidas de entropia foram calculadas diretamente a partir do sinal de ECG em amplitude e não considerando os intervalos RR. Nesse contexto, a SVT tende a apresentar maior complexidade em função do aumento da densidade de eventos em janelas temporais curtas.


Em síntese, os resultados indicam que, apesar de as medidas clássicas de entropia serem capazes de capturar características dos ritmos cardíacos, a RMEEn se destaca como a abordagem individual mais eficaz na maioria dos cenários avaliados. Contudo, essa superioridade pode estar relacionada à maior dimensionalidade do seu vetor de características, o que motivou a investigação de combinações em pares de medidas clássicas de entropia como estratégia para mitigar essa discrepância dimensional.

A Tabela 3 apresenta os resultados da classificação binária para os mesmos ritmos cardíacos analisados anteriormente, agora considerando combinações de medidas clássicas de entropia em pares, destacando-se em negrito aquelas com acurácia igual ou superior à RMEEn. Registra-se que, embora todas os pares de combinações tenham sido avaliados, foram reportados somente aqueles com desempenho mais consistente. De modo geral, evidencia-se o caráter complementar dessas medidas de entropia, uma vez que as combinações tendem a igualar ou superar o desempenho da RMEEn em diversos cenários.

**Tabela 3. Acurácia da Classificação Binária com pares de medidas clássicas.**

Ritmos	Participantes	Acurácia (%) do par de medida de entropia [ $k = 10$ ]			
		SampEn & SVDEn	SampEn & SpecEn	SpecEn & SVDEn	SpecEn & Shannon
SR × SB	5.713	<b>88,2 ± 1,4</b>	84,0 ± 2,0	85,8 ± 1,4	76,5 ± 1,1
SR × AFIB	3.605	<b>84,9 ± 1,5</b>	<b>86,6 ± 2,4</b>	<b>86,4 ± 2,1</b>	<b>85,4 ± 1,5</b>
SR × ST	3.389	86,4 ± 1,9	84,5 ± 1,5	84,6 ± 2,4	80,1 ± 1,4
SR × SVT	2.369	<b>97,6 ± 0,9</b>	96,9 ± 1,1	<b>97,7 ± 1,0</b>	96,8 ± 1,0
SR × AF	2.263	<b>91,7 ± 1,9</b>	91,6 ± 1,3	87,3 ± 1,6	89,6 ± 2,0
SR × SI	2.222	<b>81,2 ± 1,0</b>	<b>84,1 ± 2,0</b>	<b>85,5 ± 2,1</b>	<b>85,0 ± 2,6</b>

A combinação *SampEn* & *SVDEn* apresentou o melhor desempenho global, com altas acurácias em todos os casos, inclusive superando a *RMEn* na maioria deles. Esse resultado indica que a combinação de medidas sensíveis à regularidade temporal e à decomposição estrutural do sinal captura aspectos complementares da dinâmica cardíaca. A Figura 4 ilustra a distribuição dos ritmos cardíacos no plano *SampEn*–*SVDEn*, na qual se observa a separação entre determinados ritmos, em especial no par *SR*×*SVT*, que apresentou as maiores taxas de acurácia.



**Figura 4. Plano bidimensional definido pelas medidas *SampEn* e *SVDEn*. Cada ponto representa a mediana das medidas de entropia agregadas ao longo das 12 derivações do ECG para os sete ritmos mais frequentes da base de dados (ver Tabela 1), enquanto as barras de erro correspondem ao intervalo interquartil, refletindo a variabilidade entre as derivações.**

Ainda em relação à Tabela 3, no cenário *SR*×*AFIB* observa-se que todos os pares de entropia reportados alcançaram acurácias superiores à *RMEn*. A *AFIB* (Fibrilação Atrial) é caracterizada por uma ativação atrial extremamente rápida, tipicamente superior a 400 bpm, e desorganizada tanto no domínio espacial quanto temporal [Prystowsky et al. 2020]. Logo, os resultados sugerem que a combinação de medidas de entropia distintas em pares é capaz de capturar características complementares deste ritmo que não são plenamente exploradas pela *RMEn* de forma isolada.

Por outro lado, no cenário *SR*×*ST*, nenhuma das combinações reportadas superou a *RMEn*. A *ST* (Taquicardia Sinusal) é caracterizada pela frequência cardíaca superior a 100 bpm, geralmente resultante de exercício físico, ansiedade, febre, anemia ou até mesmo pelo consumo de álcool e nicotina [Prystowsky et al. 2020]. Nesse contexto, o

desempenho superior da RMEn pode ser atribuído à sua maior sensibilidade a alterações nos microestados de recorrência resultantes do aumento da frequência cardíaca, mesmo quando a morfologia do ECG em amplitude permanece semelhante à do SR.

Em suma, a combinação de medidas clássicas de entropia em pares apresentou desempenho equivalente à RMEn na classificação binária, evidenciando o potencial de complementaridade dessas medidas na discriminação automática de ritmos cardíacos.

### 3.2. Classificação Multiclasse

Para a classificação multiclasse, foram considerados os quatro ritmos cardíacos mais frequentes na base de dados (SR, SB, AFIB e ST), que correspondem a aproximadamente 85% das amostras. A Tabela 4 apresenta os resultados obtidos tanto com as medidas de entropia individuais quanto com as combinações em pares. De forma consistente com os resultados obtidos no cenário anterior, observa-se um ganho significativo de desempenho ao combinar medidas clássicas de entropia, com destaque para os pares *SampEn & SpecEn* (78,1%) e *SampEn & SVDEn* (77,6%).

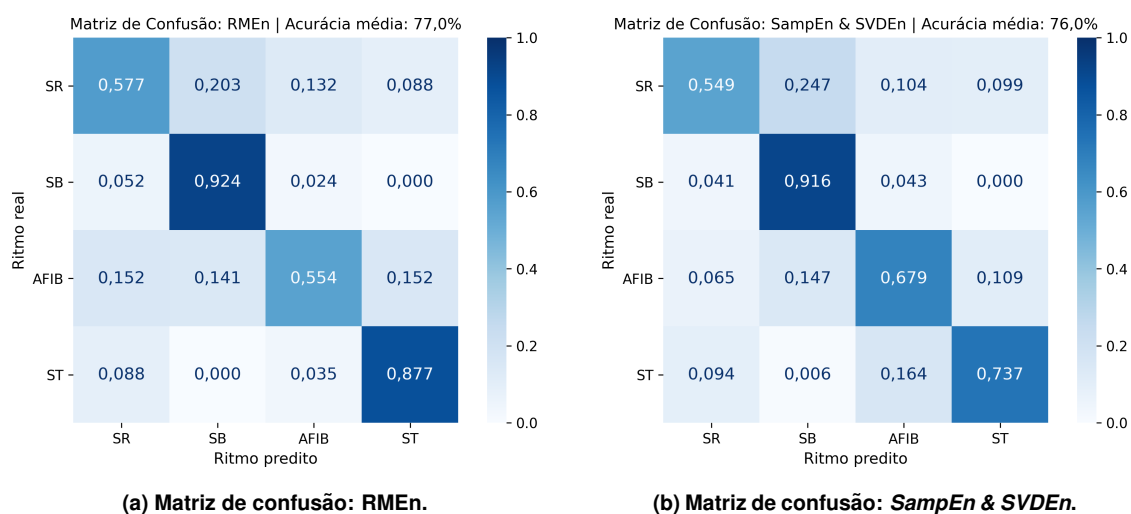
**Tabela 4. Acurácia da Classificação Multiclasse.**

Entropia	Acurácia (%) [Participantes: 9.057]
	SR × SB × AFIB × ST
PermEn	52,6 ± 3,4
SampEn	73,0 ± 1,6
Shannon	54,9 ± 1,7
SpecEn	58,1 ± 2,4
SVDEn	65,9 ± 2,2
SampEn & SVDEn	77,6 ± 2,1
SampEn & SpecEn	78,1 ± 1,7
SpecEn & SVDEn	75,7 ± 2,2
SpecEn & Shannon	67,5 ± 2,0
RMEn	79,5 ± 1,5

Embora a RMEn tenha alcançado o melhor desempenho (79,5%), a diferença em relação aos pares de medidas clássicas de entropia com melhores resultados não foi expressiva, sobretudo quando se consideram as vantagens adicionais dessas medidas, como o menor custo computacional e a maior simplicidade de implementação.

A Figura 5 apresenta as matrizes de confusão obtidas na primeira dobra da validação cruzada ( $k = 1$ ) no cenário de classificação multiclasse, considerando a RMEn (Figura 5a) e o par *SampEn & SVDEn* (Figura 5b), que foi a combinação com melhor desempenho na classificação binária. De modo geral, ambas as matrizes exibem padrões de desempenho semelhantes, com elevadas taxas de acerto para o ritmo SB, superiores a 90%. Observa-se, que a combinação *SampEn & SVDEn* se destaca na discriminação do ritmo AFIB, em consonância com os resultados observados na classificação binária.

Apesar dos resultados obtidos serem promissores, este trabalho apresenta algumas limitações. Primeiro, a investigação restringiu-se ao uso de ANNs, limitando a análise sobre o impacto das características em relação à arquitetura do classificador. Além disso,



**Figura 5. Matrizes de confusão normalizadas no cenário de classificação multi-classe (SR, SB, AFIB e ST), na primeira dobra da validação cruzada ( $k = 1$ ), utilizando: (a) a RMEEn, e (b) o par *SampEn & SVDEn*.**

não foram exploradas arquiteturas mais modernas de aprendizado profundo, como Redes Neurais Convolucionais (CNNs), Redes Neurais Recorrentes (RNN) ou *Transformers*. Adicionalmente, foram consideradas todas as 12 derivações do sinal de ECG, sem avaliar o impacto de derivações específicas na tarefa de classificação.

Os vetores de características foram compostos exclusivamente por medidas de entropia. Em trabalhos relacionados, como em [Oliveira et al. 2022], além de atributos extraídos dos sinais de ECG no domínio da frequência por meio da Transformada Wavelet Discreta, foram incorporados atributos clínicos e morfológicos, como idade, sexo e parâmetros associados ao complexo QRS. Por último, não foram adotadas estratégias de balanceamento entre as classes de ritmos, contudo o objetivo foi preservar a distribuição dos dados e refletir um cenário mais próximo da prática clínica real.

#### 4. Conclusão

Este trabalho comparou o uso de seis medidas de entropia aplicadas à detecção automática de arritmias cardíacas a partir de sinais de ECG de 12 derivações de curta duração utilizando ANNs. Foram avaliadas cinco medidas clássicas de entropia (PermEn, SampEn, Shannon, SpecEn, SVDEn) tanto individualmente quanto em pares, além da RMEEn, proposta recentemente [Boaretto et al. 2024].

Os resultados demonstraram que, tanto no cenário de classificação binária quanto no multiclasse, a combinação de medidas clássicas de entropia em pares leva a ganhos consistentes de desempenho, equiparando ou até superando a RMEEn em determinados casos. De forma geral, o par *SampEn & SVDEn* destacou-se por apresentar desempenho robusto no processo classificatório ao longo dos diferentes cenários analisados, indicando que a integração de medidas baseadas na regularidade temporal e na decomposição estrutural do sinal é eficaz para capturar aspectos relevantes da dinâmica cardíaca.

Os resultados reforçam, ainda, que as medidas de entropia são importantes descritores para a classificação de ritmos cardíacos a partir de sinais de ECG e que a combinação

adequada de medidas clássicas de entropia permite equilibrar desempenho competitivo, menor custo computacional e simplicidade de implementação.

Como trabalhos futuros, propõe-se investigar o desempenho das medidas de entropia em arquiteturas modernas de aprendizado profundo, bem como avaliar o impacto do uso de derivações específicas do ECG na extração de características e a aplicação de técnicas de balanceamento de dados. Adicionalmente, pretende-se explorar estratégias multiescala e de fusão multimodal. Por fim, é importante analisar a aplicabilidade dessas abordagens em cenários de monitoramento contínuo, visando o desenvolvimento de sistemas mais robustos e eficientes na detecção automática de arritmias cardíacas.

## Agradecimentos

Este trabalho foi totalmente financiado pelo projeto *Advanced Multimodal Sensing* (AIMS), apoiado pelo Centro de Competência em Tecnologias Imersivas (AKCIT), com recursos financeiros do PPI IoT do MCTI, sob o convênio nº 057/2023, firmado com a EMBRAPPI. Os autores também agradecem à Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG) pelo apoio financeiro concedido a esta pesquisa (Fomento nº 64448878/2024). Reconhece-se a disponibilização do código por [Boaretto et al. 2024].

## Referências

- Asgharzadeh-Bonab, A., Amirani, M. C., and Mehri, A. (2020). Spectral entropy and deep convolutional neural network for ecg beat classification. *Biocybernetics and Bio-medical Engineering*, 40(2):691–700.
- Bandt, C. and Pompe, B. (2002). Permutation entropy: a natural complexity measure for time series. *Physical review letters*, 88(17):174102.
- Boaretto, B. R. R. et al. (2024). The use of entropy of recurrence microstates and artificial intelligence to detect cardiac arrhythmia in ecg records. *Applied Mathematics and Computation*, 475:128738.
- Corso, G., Prado, T. L. d. L., Lima, G. Z. d. S., Kurths, J., and Lopes, S. R. (2018). Quantifying entropy using recurrence matrix microstates. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 28(8).
- Henriques, T., Ribeiro, M., Teixeira, A., Castro, L., Antunes, L., and Costa-Santos, C. (2020). Nonlinear methods most applied to heart-rate time series: A review. *Entropy*, 22(3):309.
- Inouye, T., Shinosaki, K., Sakamoto, H., Toi, S., Ukai, S., Iyama, A., Katsuda, Y., and Hirano, M. (1991). Quantification of eeg irregularity by use of the entropy of the power spectrum. *Electroencephalography and Clinical Neurophysiology*, 79(3):204–210.
- Jiang, W. and Wang, J. (2024). Classification of ecg signals based on local fractal feature. *Multimedia Tools and Applications*, 83(18):54773–54789.
- Kim, S. H., Lim, K. R., Seo, J.-H., Ryu, D. R., Lee, B.-K., Cho, B.-R., and Chun, K. J. (2022). Higher heart rate variability as a predictor of atrial fibrillation in patients with hypertension. *Scientific Reports*, 12(1):3702.
- Lindstrom, M. et al. (2022). Global burden of cardiovascular diseases and risks collaboration, 1990–2021. *Journal of the American College of Cardiology*, 80(25):2372–2425.

- Liu, C., Oster, J., Reinertsen, E., Li, Q., Zhao, L., Nemati, S., and Clifford, G. D. (2018). A comparison of entropy approaches for af discrimination. *Physiological Measurement*, 39(7):074002.
- Mandal, S., Roy, A. H., and Mondal, P. (2025). Discrimination of life-threatening arrhythmias using self-adaptive vmd, rqa techniques and efficientnetv2-l classifier. *Biomedical Signal Processing and Control*, 110:108301.
- Neha, Sardana, H., Kanwade, R., and Tewary, S. (2021). Arrhythmia detection and classification using ecg and ppg techniques: A review. *Physical and Engineering Sciences in Medicine*, 44(4):1027–1048.
- Oliveira, R. F., Ferreira, A. A., Moreira, G. J. P., and Luz, E. J. S. (2022). Um Método Ensemble para Classificação de Arritmias: Uma Avaliação com Mais de 10 Mil Registros de Sinais de ECG. In *Anais do Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*, pages 13–24. SBC.
- Prado, T. L., Corso, G., Lima, G. Z. d. S., Budzinski, R. C., Boaretto, B. R. R., Ferrari, F. A. S., Macau, E. E. N., and Lopes, S. R. (2020). Maximum entropy principle in recurrence plot analysis on stochastic and chaotic systems. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 30(4).
- Prystowsky, E. N., Klein, G. J., and Daubert, J. P. (2020). *Cardiac Arrhythmias: Interpretation, Diagnosis and Treatment*. McGraw Hill Professional.
- Rahul, J. and Sharma, L. D. (2025). Advancements in ai for cardiac arrhythmia detection: A comprehensive overview. *Computer Science Review*, 56:100719.
- Rathnayake, C., Chen, W., Ran, G., Zhang, H., Thilakarathne, B. S., Lai, D., et al. (2026). Multimodal ecg–ppg wearable technologies and modern fusion methods for atrial fibrillation detection: A review. *IEEE Sensors Journal*.
- Richman, J. S. and Moorman, J. R. (2000). Physiological time-series analysis using approximate entropy and sample entropy. *American Journal of Physiology - Heart and Circulatory Physiology*, 278(6):H2039–H2049.
- Schnabel, R. B. et al. (2023). Early diagnosis and better rhythm management to improve outcomes in patients with atrial fibrillation: the 8th afnet/ehra consensus conference. *Europace*, 25(1):6–27.
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3):379–423.
- Śmigiel, S., Pałczyński, K., and Ledziński, D. (2021). Ecg signal classification using deep learning techniques based on the ptb-xl dataset. *Entropy*, 23:1121.
- Sridhar, A. R. et al. (2024). State of the art of mobile health technologies use in clinical arrhythmia care. *Communications Medicine*, 4(1):218.
- Sridhar, C., Lih, O. S., Jahmunah, V., Koh, J. E., Ciaccio, E. J., San, T. R., Arunkumar, N., Kadry, S., and Rajendra Acharya, U. (2021). Accurate detection of myocardial infarction using non linear features with ecg signals. *Journal of Ambient Intelligence and Humanized Computing*, 12(3):3227–3244.
- Zheng, J. et al. (2020). A 12-lead electrocardiogram database for arrhythmia research covering more than 10,000 patients. *Scientific Data*, 7(1):48.