

Análise de Recorrência na Classificação de ECGs: Um Estudo com Modelos Profundos e Clássicos

João Pagnan, Romis Attux, Diogo Soriano e Levy Boccato

Resumo—A detecção precoce de arritmias a partir de eletrocardiogramas (ECGs) pode ser decisiva para o tratamento de doenças cardiovasculares, que ainda são a principal causa de mortes no mundo. Muitos trabalhos têm explorado técnicas de processamento de sinais e aprendizado de máquina neste problema, havendo já iniciativas que empregam gráficos de recorrência para a caracterização dos sinais cardíacos. Porém, poucos trabalhos realizaram uma comparação mais ampla com outras estratégias de representação dos ECGs junto a diferentes classificadores. Neste trabalho, aplicamos a análise de recorrência para descrever os ECGs da base MIT-BIH ARR, avaliando seu impacto sobre modelos tradicionais e profundos (e.g., ResNet) de classificação. Além disso, avaliamos também as representações temporais e os espectrogramas (SPGs). Os resultados obtidos indicam que TS com k -vizinhos mais próximos alcançaram a melhor F-medida (0,7980), enquanto os gráficos de distância (DPs) com KNN fornecem a maior precisão e especificidade, além de superarem consistentemente os desempenhos atingidos com os gráficos de recorrência (RPs).

Palavras-Chave—Eletrocardiogramas, processamento de sinais, análise de recorrência, aprendizado profundo.

Abstract—Early detection of arrhythmias from electrocardiograms (ECGs) can be decisive for the treatment of cardiovascular diseases, which remain the leading cause of death worldwide. Many studies have explored signal processing and machine learning techniques for this problem, and there are already initiatives employing recurrence plots to characterize cardiac signals. However, few works have conducted a broader comparison with other ECG representation strategies in combination with different classifiers. In this work, we apply recurrence analysis to describe ECGs from the MIT-BIH ARR dataset, evaluating its impact on both traditional and deep classification models (e.g., ResNet). Additionally, we also evaluate temporal representations and spectrograms (SPGs). The results indicate that TS with k -nearest neighbors achieved the best F1 Score (0.7980), while distance plots (DPs) with KNN yielded the highest precision and specificity, consistently outperforming the results obtained with recurrence plots (RPs).

Keywords—Electrocardiograms, signal processing, recurrence analysis, deep learning.

I. INTRODUÇÃO

As doenças cardiovasculares (CVDs, do inglês *cardiovascular diseases*) são a principal causa de morte no mundo. Estima-se que 17,9 milhões de pessoas morreram por CVDs em 2019, representando 32% de todas as mortes em nível global desse ano [1]. Além disso, mais de três quartos das mortes por CVDs ocorrem em países de baixa e média renda [2].

João Pagnan, Romis Attux e Levy Boccato, Faculdade de Engenharia Elétrica e de Computação (FEEC), Universidade Estadual de Campinas (UNICAMP), e-mail: j199727@dac.unicamp.br; attux@unicamp.br; lboccatto@unicamp.br. Diogo C. Soriano, Universidade Federal do ABC (UFABC), diogo.soriano@ufabc.edu.br

Grande parte das mortes causadas por CVDs pode ser atribuída ao tipo de arritmia cardíaca de fibrilação ventricular e à parada cardíaca súbita. As arritmias são caracterizadas por alterações irregulares nos ciclos cardíacos e podem se manifestar de acordo com alguns tipos, tais como batimentos prematuros, fibrilação atrial e arritmia ventricular [3].

O tratamento eficaz de CVDs depende da detecção da doença num estágio inicial, o que pode ser feito através da análise dos eletrocardiogramas (ECGs, do inglês *electrocardiograms*) [3], buscando identificar padrões que evidenciam a provável manifestação de uma CVD. Um sinal de ECG é um registro da atividade elétrica das células musculares cardíacas ao longo do tempo feito com o uso de eletrodos colocados sobre o peitoral, pulsos e tornozelos de um paciente [4]. A Figura 1 traz um exemplo do típico curso temporal do ECG.

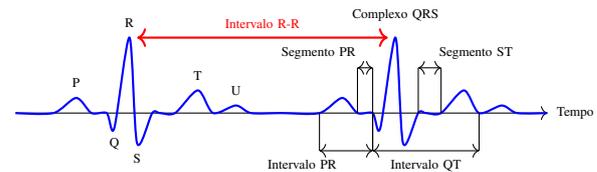


Fig. 1. Exemplo de uma onda registrada por um ECG com alguns de seus segmentos e intervalos. Os segmentos indicam a duração das linhas isoeletricas entre as ondulações (P, Q, R, S, T e U), e os intervalos o período de tempo entre segmentos de ondulações adjacentes.

A identificação de padrões em sinais fisiológicos tem sido útil para auxiliar o diagnóstico clínico de diferentes condições e/ou doenças. Em particular, padrões derivados de ECGs são estudados também em outras aplicações, como para a detecção de apneia do sono [5], biometria [6] e estresse emocional [7].

Nas últimas décadas, esse problema tem sido abordado com ferramentas de aprendizado de máquina (ML, do inglês *machine learning*), assim como por técnicas de processamento de sinais, tais como a análise tempo-frequência [8]. O trabalho de Venkatesan *et al.* [9] aplicou o algoritmo de k -vizinhos mais próximos (KNN, do inglês *k-nearest neighbors*) para a classificação de atributos (em inglês, *features*) de variabilidade da frequência cardíaca [4] extraídos com uma filtragem adaptativa baseada em algoritmos de mínimos quadrados médios aplicada a ECGs da base MIT-BIH de arritmias (MIT-BIH ARR, do inglês *MIT-BIH Arrhythmia Database*) [10]. No trabalho de Kumar *et al.* [11] essa base de dados foi utilizada para a categorização de atributos de arritmias, extraídos com a transformada discreta do cosseno, com modelos de florestas aleatórias (RF, do inglês *random forest*). Por sua vez, Sannino *et al.* [12] exploraram o emprego de modelos profundos na

detecção de ciclos cardíacos anormais nos ECGs da base MIT-BIH ARR. Os modelos considerados no trabalho utilizaram trechos com duração de 140 ms e quatro atributos temporais derivados do intervalo R-R, e o melhor classificador foi uma rede MLP (*multilayer perceptron*).

A motivação para o emprego de modelos profundos decorre do sucesso que eles têm tido em tarefas de diferentes domínios, como processamento de linguagem natural e visão computacional, e pelo fato de serem capazes de identificar atributos relevantes a partir dos dados brutos enquanto aprendem a resolver a tarefa. Em [13], um modelo profundo baseado na arquitetura ResNet foi utilizado para classificar sinais da base MIT-BIH ARR e, também, coletados em um hospital da cidade de Braga, em Portugal.

Outra linha de trabalhos tem lançado mão do arcabouço teórico de sistemas dinâmicos e dinâmica caótica para a detecção e análise de sinais temporais de ECGs, tais como gráficos de recorrência (RPs, do inglês *recurrence plots*), de distância (DPs, do inglês *distance plots*) e métricas de análise quantitativa de recorrência (RQA, do inglês *recurrence quantification analysis*). Além disso, a representação de sinais temporais por RPs e RQA pode, em alguns contextos, trazer à tona aspectos dos dados que facilitem a discriminação das classes, como, por exemplo, na detecção de CVDs [14].

A RQA tem sido amplamente empregada na caracterização de arritmias cardíacas e outras condições clínicas. Estudos apontam sua eficácia na identificação de eletrogramas associados à fibrilação atrial persistente, com potencial aplicação na ablação de substratos arritmogênicos ([15] e [14]). Além disso, a RQA tem sido utilizada para a diferenciação de mecanismos específicos de *flutter* atrial por meio de simulações computacionais aplicadas a sinais de ECG de 12 derivações [16]. Em outro contexto, sua aplicação em vetocardiogramas mostrou-se promissora na detecção de infarto agudo do miocárdio [17].

Com o intuito de avaliar o potencial de discriminação dos RPs e DPs, realizamos neste trabalho um estudo comparativo entre diferentes abordagens de representação dos ECGs no contexto da identificação de ciclos cardíacos anormais, considerando tanto modelos tradicionais de ML quanto modelos profundos, tendo em vista que a literatura ainda carece de comparações mais detalhadas das ferramentas de recorrência com outras representações (e.g., tempo-frequência).

A Seção II apresenta a fundamentação teórica da análise de recorrência, enquanto na Seção III detalhamos a base de dados utilizada, o pré-processamento dos ECGs, as representações consideradas para tais sinais e os classificadores selecionados para avaliação. A Seção IV discute os resultados atingidos e, por fim, a Seção V encerra o artigo com as conclusões obtidas e as perspectivas de trabalhos futuros.

II. FUNDAMENTAÇÃO TEÓRICA

Eckmann et al. [18] propuseram a ideia de RP para permitir a visualização das recorrências existentes num sistema dinâmico. Em termos matemáticos, considere $\mathbf{x}_i \in \mathbb{R}^d$ o i -ésimo ponto da órbita de um sistema dinâmico, sendo d a quantidade de variáveis independentes deste sistema e $i \in \mathbb{Z}$, $1 \leq i \leq N$, onde N é o número de pontos da órbita. O

gráfico de recorrência corresponde a uma matriz $\mathbb{R}_{N \times N}$, na qual o elemento (i, j) é definido como [19]:

$$\mathbf{R}_{i,j} = \begin{cases} 1 : \mathbf{x}_i \approx \mathbf{x}_j, \\ 0 : \mathbf{x}_i \not\approx \mathbf{x}_j, \end{cases} \quad i, j = 1, \dots, N, \quad (1)$$

onde $\mathbf{x}_i \approx \mathbf{x}_j$ se, e somente se, $d(\mathbf{x}_i, \mathbf{x}_j) \leq \varepsilon$, sendo $d(\cdot)$ uma métrica de distância e ε o limiar de similaridade.

Uma forma de construir a trajetória de um sistema a partir de uma sequência de medidas escalares $u_i = u(i\Delta t)$, sendo $i = 1, \dots, N$ e Δt o intervalo temporal entre as amostras, consiste em empilhar atrasos consecutivos até uma dimensão m de imersão (em inglês, *embedding*), de modo que:

$$\mathbf{x}_i = \sum_{j=1}^m u_{i+(j-1)\tau} \mathbf{e}_j, \quad (2)$$

onde τ é o atraso temporal entre as amostras utilizadas para a construção da trajetória e \mathbf{e}_i são vetores d -dimensionais ortonormais [19].

Há diferentes abordagens para a determinação dos parâmetros m e τ , como o algoritmo dos falsos vizinhos mais próximos (FNN, do inglês *false nearest neighbor*) para a estimativa da dimensionalidade m da imersão e o uso da função de autocorrelação e de informação mútua para a definição do atraso τ considerado [19].

Também é possível representar a relação indicada em (1) através da seguinte equação [19]:

$$\mathbf{R}_{i,j}(\varepsilon) = \Theta(\varepsilon - \|\mathbf{x}_i - \mathbf{x}_j\|), \quad i, j = 1, \dots, N, \quad (3)$$

sendo $\Theta(\cdot)$ a função de Heaviside ($\Theta(x) = 0$ se $x < 0$ e, caso contrário, $\Theta(x) = 1$) e $\|\cdot\|$ é a norma utilizada.

Desse modo, para gerar um RP é preciso escolher a norma L_p de um vetor $\mathbf{x} = (x_1, x_2, \dots, x_N)$, definida na equação (4) [20], e calcular a distância entre os estados \mathbf{x}_i e \mathbf{x}_j . As normas mais comumente utilizadas são a L_1 (norma de Manhattan), L_2 (norma euclidiana) e L_∞ (norma de Chebyshev).

$$L_p(\mathbf{x}) = \|\mathbf{x}\|_p = \left(\sum_{i=1}^N |x_i|^p \right)^{1/p} \quad (4)$$

Também é necessário definir um valor adequado para o limiar ε : se ε for muito pequeno, pode haver quase nenhum ponto \mathbf{x}_j na vizinhança de \mathbf{x}_i , impossibilitando a visualização da estrutura de recorrência do sistema. Por outro lado, se ε for grande, a vizinhança em torno de qualquer ponto acabará abrangendo muitos pontos, originando artefatos no RP [19].

Há diversos métodos para a escolha do limiar ε , como, por exemplo, a partir da fração do diâmetro máximo do espaço de fase, baseando-se na quantidade de vizinhos do ponto \mathbf{x}_i , ou, então, levando em conta que o processo de medida tem um ruído com desvio padrão σ [19].

É possível, também, considerar a informação de recorrência antes da aplicação do limiar ε , ou seja, utilizar os próprios valores de $d(\mathbf{x}_i, \mathbf{x}_j)$. Tal gráfico é chamado por Marwan *et al.* [19] de gráfico de distância (DP).

Foram propostas algumas métricas de complexidade em RPs baseando-se na densidade de pontos de recorrência e nas estruturas de linhas diagonais e verticais presentes no RP e a

métrica mais simples de RQA é a taxa de recorrência (RR, do inglês *recurrence rate*), a qual indica a densidade de pontos de recorrência no RP [19]:

$$RR(\varepsilon) = \frac{1}{N^2} \sum_{i,j=1}^N \mathbf{R}_{i,j}(\varepsilon) \quad (5)$$

III. MATERIAIS E MÉTODOS

A. Base de Dados

Utilizamos a base MIT-BIH ARR [10], disponível no repositório PhysioNet [21], construída com o registro de mais de quatro mil gravações Holter [22] e é uma das mais empregadas em trabalhos de identificação de arritmias.

Das quatro mil gravações, 23 registros foram selecionados aleatoriamente para compor a base e outros 25 foram escolhidos para incluir fenômenos raros mas clinicamente importantes. Os registros têm duração aproximada de 30 minutos e contêm sinais de ECGs de 25 homens, entre 32 e 89 anos, e 22 mulheres com idades entre 23 e 89 anos. Os registros 201 e 202 da base se referem ao mesmo paciente do sexo masculino.

As gravações foram digitalizadas com taxa de amostragem de 360 Hz e resolução de 11 bits numa faixa de ± 5 mV [10]. Na maioria dos registros, o primeiro canal corresponde a uma derivada modificada do membro II (MLII) e o segundo é o sinal de uma derivada modificada de V1 (ocasionalmente V2 ou V5, e em um caso, V4) [10].

Cada ECG teve os ciclos cardíacos categorizados por dois ou mais cardiologistas, além de anotações atreladas ao ritmo cardíaco [10]. Agrupamos os quinze rótulos de ciclos em cinco classes do padrão ANSI/AAMI-EC57 [23] e, para atenuar o desbalanceamento, como feito em [12], a classe do tipo de sinal não identificado foi desconsiderada e os quatro rótulos restantes foram agrupados em duas categorias: *i*) ‘N’: ciclos cardíacos normais; e *ii*) ‘A’: ciclos cardíacos anormais.

Como feito em [12], as gravações 101, 106, 108, 109, 112, 114, 115, 116, 118, 119, 122, 124, 201, 203, 205, 207, 208, 209, 215, 220, 223 e 230 formam o conjunto de treinamento, e os registros 100, 103, 105, 111, 113, 117, 121, 123, 200, 202, 210, 212, 213, 214, 219, 221, 222, 228, 231, 232, 233 e 234 o conjunto de teste. Os sinais 102, 104, 107, e 217 foram desconsiderados, pois pertencem a pessoas que utilizam marca-passo [12].

O conjunto de treinamento possui 45856 ciclos da classe ‘N’ e 5146 do tipo ‘A’, e o conjunto de teste possui 44246 registros da primeira e 5445 da segunda.

B. Pré-processamento dos Sinais

1) *Filtragem*: Seguindo o procedimento de outros trabalhos da literatura [24], os dois canais de ECGs foram filtrados com um filtro passa-banda de segunda ordem de 0,1 a 100 Hz, para remover ruídos de desvio da linha de base, e um filtro *notch* de 50 Hz com o parâmetro Q igual a 5, para eliminar interferência da rede elétrica [25].

A Figura 2 mostra o canal MLII da gravação 101 da base antes e após a filtragem.

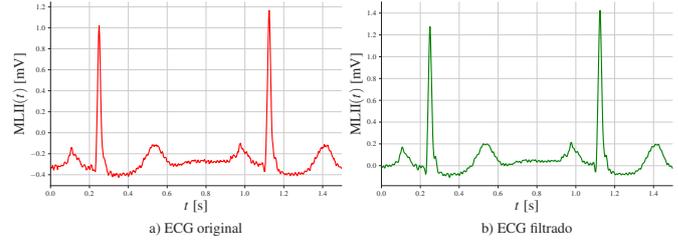


Fig. 2. Filtragem dos ECGs.

2) *Segmentação dos Ciclos Cardíacos*: Cada ciclo cardíaco da gravação foi segmentado e associado ao rótulo correspondente. A segmentação foi feita com uma janela 0,5 segundos e a amostra central das janelas corresponde ao pico R nos sinais de ECGs. A posição desses pontos foi anotada pelos cardiologistas responsáveis pelo processo de categorização de ciclos cardíacos da base MIT-BIH ARR [10].

C. Representações

As representações avaliadas para os ECGs foram: *(i)* séries temporais (TS, do inglês *time series*); *(ii)* espectrogramas (SPGs, do inglês *spectrograms*), *(iii)* DPs; e *(iv)* RPs.

As TS se referem ao sinal temporal do ciclo cardíaco nos dois canais, sem transformações adicionais após o pré-processamento. Os SPGs de cada canal foram construídos com uma janela de Hann de 64 amostras por segmento e com uma sobreposição de 50%, garantindo uma boa resolução em frequência sem sacrificar a resolução temporal, e evitando o vazamento espectral com a janela escolhida.

Os DPs e RPs foram criados medindo a distância entre os pontos i e j da trajetória dos ECGs quando são incorporados a uma trajetória num espaço de dimensão m através do teorema de Takens [26]. Destacamos que cada canal de ECG teve a sua trajetória no espaço de fase construída conforme o teorema.

Tomando como base as orientações gerais de Marwan *et al.* [27] para a construção dos gráficos de recorrência, utilizamos neste trabalho a norma L_2 , uma dimensão de imersão m igual a 3 e um atraso τ igual a 9. Para determinar os valores para τ e m , calculamos a média do valor de τ no primeiro mínimo na curva de informação mútua nos dois canais para todos os sinais do conjunto de treinamento e, com esse valor, utilizamos o algoritmo dos FNN para verificar qual m anulava a quantidade de falsos vizinhos mais próximos. O limiar ε escolhido foi igual a 0,035, fazendo com que, em média, a taxa de recorrência dos RPs de cada canal dos sinais de treinamento seja próxima de 6%.

A Figura 3 mostra as representações dos dois canais para sinais de ECGs registrados nas gravações 101, 208, 230 e 223, que fazem parte do conjunto de treinamento. Para facilitar a visualização, limitamos a frequência máxima nos espectrogramas em 45 Hz.

É possível enxergar perfis distintos entre as amostras das duas classes nas diferentes representações, assim como variações entre sinais do tipo ‘A’. É interessante notarmos como o complexo QRS corresponde a um aumento na distância entre os pontos nos DPs e RPs.

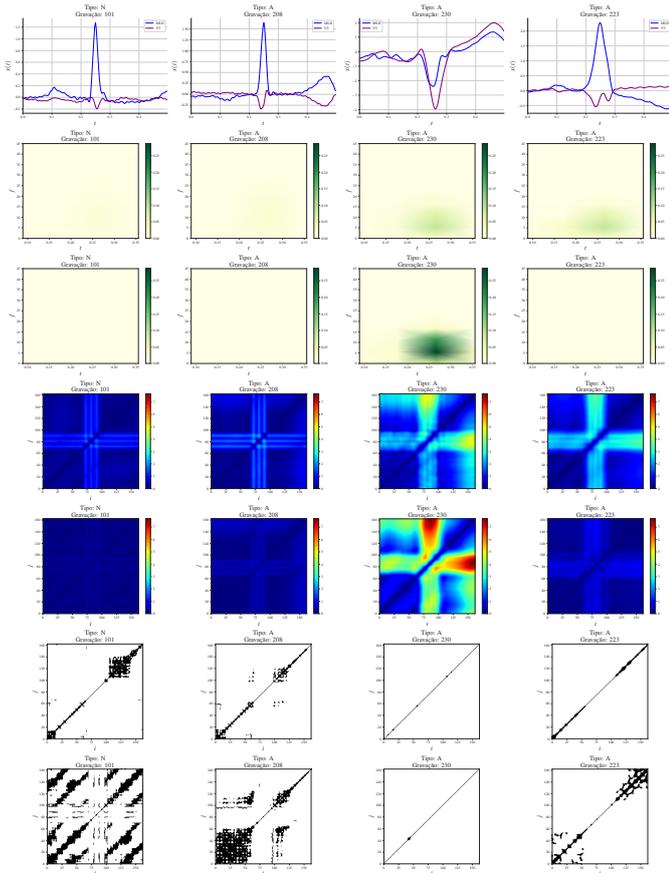


Fig. 3. Ciclos cardíacos das classes ‘N’ e ‘A’ nos canais MLII e V5 das gravações 101, 208, 213 e 223 e suas conversões em SPGs, DPs e RPs.

D. Classificadores

Consideramos os modelos de classificação KNN, RF, MLP e ResNet, avaliando os respectivos desempenhos com as métricas de acurácia, precisão, sensibilidade, especificidade e F-medida.

No caso do KNN, realizamos uma busca pelo número de vizinhos, considerando os valores de 1, 5, 10, 50, 100, 500 e 1000. De forma semelhante, testamos os mesmos valores para o número de árvores no algoritmo RF. Na Seção IV, informamos a parametrização que atingiu a melhor F-medida na etapa de validação.

Consideramos uma MLP simples com duas camadas ocul-tas, função de ativação *ReLU* nas camadas intermediárias e *Softmax* nos neurônios de saída, e inicializações He e Glorot uniforme, respectivamente. As camadas intermediárias possuem 100 e 50 neurônios, respectivamente.

Em relação aos modelos profundos, foram empregadas as redes convolucionais ResNet18, ResNet34 e ResNet50. No caso da representação TS, estas arquiteturas foram adaptadas para realizar operações unidimensionais.

Para a MLP e ResNet, utilizamos o otimizador Adam, critério de entropia cruzada e taxa de aprendizagem de 0,001. Para a representação TS, as ResNets foram inicializadas de forma aleatória e treinadas por completo; nas demais representações, utilizamos como condição inicial os pesos dos modelos pré-treinados na ImageNet, fazendo o ajuste fino apenas das

camadas de entrada e de saída.

O treinamento durava, no máximo, 100 épocas, mas utilizamos a técnica de parada antecipada (em inglês, *early stopping*) para evitar o sobreajuste dos modelos. O conjunto de validação corresponde a 20% dos dados do conjunto de treinamento selecionados aleatoriamente, fazendo com que no treino houvesse 36685 ciclos cardíacos do tipo ‘N’ e 4117 do ‘A’, e na validação 9171 da classe ‘N’ e 1029 da ‘A’.

A inicialização, treinamento e teste dos modelos profundos foram repetidos cinco vezes para obtermos um valor médio e desvio padrão para as métricas de avaliação.

As representações foram avaliadas independentemente, sendo fornecido aos modelos os dois canais de TS, SPGs, RPs ou DPs, dos sinais dos ciclos cardíacos, sem nenhuma extração de atributos ou transformações adicionais.

Na próxima seção, são apresentados os resultados obtidos.

IV. RESULTADOS

A Tabela I exibe os valores das métricas de avaliação alcançados por cada classificador para as quatro representações consideradas (TS, SPGs, RPs e DPs). Em negrito, são destacados os melhores resultados (em termos de F-medida) para cada representação.

TABELA I
RESULTADOS OBTIDOS PELOS CLASSIFICADORES PARA CADA REPRESENTAÇÃO.

Representação	Modelo	Acurácia	Precisão	Sensibilidade	Especificidade	F-medida
TS	KNN(100)	0.9343	0.8174	0.5153	0.9858	0.7980
	RF(100)	0.8678	0.4280	0.6136	0.8991	0.7140
	MLP	0.7773 ± 0.0280	0.2827 ± 0.0288	0.6529 ± 0.0165	0.7926 ± 0.0333	0.6283 ± 0.0224
	ResNet34	0.8079 ± 0.0333	0.3232 ± 0.0489	0.6422 ± 0.0205	0.8283 ± 0.0396	0.6556 ± 0.0301
SPG	KNN(50)	0.8806	0.4526	0.4263	0.9366	0.6861
	RF(1000)	0.8947	0.5155	0.6454	0.9253	0.7565
	MLP	0.8993 ± 0.0055	0.544 ± 0.030	0.5198 ± 0.0080	0.9460 ± 0.0070	0.7373 ± 0.0071
	ResNet50	0.8459 ± 0.0186	0.3610 ± 0.0428	0.4938 ± 0.0530	0.8892 ± 0.0253	0.6622 ± 0.0165
RP	KNN(100)	0.7418	0.1889	0.4118	0.7824	0.5513
	RF(50)	0.8629	0.3404	0.2683	0.9360	0.6120
	MLP	0.8400 ± 0.0080	0.353 ± 0.017	0.549 ± 0.038	0.8758 ± 0.0111	0.6680 ± 0.0106
	ResNet18	0.8594 ± 0.0206	0.4105 ± 0.0561	0.5825 ± 0.0291	0.8935 ± 0.0256	0.6985 ± 0.0223
DP	KNN(500)	0.9251	0.8234	0.4033	0.9894	0.7503
	RF(50)	0.8360	0.3677	0.6894	0.8541	0.6911
	MLP	0.8338 ± 0.0166	0.347 ± 0.0296	0.574 ± 0.0770	0.8657 ± 0.0224	0.6665 ± 0.0204
	ResNet18	0.8068 ± 0.0547	0.3374 ± 0.1164	0.6066 ± 0.0636	0.8314 ± 0.0650	0.6518 ± 0.0559

A Figura 4 mostra a distribuição dos valores da F-medida na forma de *boxplots* separados por estratégia de representação dos ECGs.

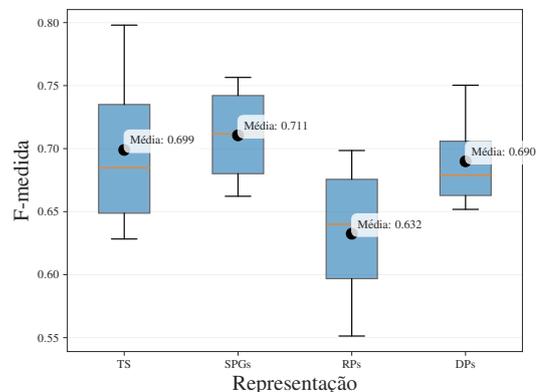


Fig. 4. *Boxplots* da F-medida obtida pelos modelos em cada representação.

O modelo que obteve o maior valor para a F-medida foi o KNN com 100 vizinhos na categorização de TS, seguido

pelo RF com 1000 árvores aleatórias para a classificação de SPGs de ECGs, KNN com 500 vizinhos aplicado a DPs, e, por último, ResNet18 aplicada à identificação de RPs.

O classificador KNN aplicado a DPs obteve a melhor precisão, especificidade e segunda melhor acurácia. Notamos uma perda no desempenho dos modelos não-profundos quando aplicados a RPs por causa da piora da precisão no KNN e redução da sensibilidade no RF, mas uma melhora no desempenho da ResNet.

É possível observar na Figura 4 uma similaridade entre os desempenhos médios obtidos para as representações TS, SPGs e DPs. Interessantemente, o uso de DPs também levou à menor dispersão dos resultados.

Com respeito aos RPs, percebemos que há uma queda considerável na média e um aumento da dispersão, indicando que a binarização que se aplica aos DPs para gerar os RPs não se mostrou benéfica para a classificação dos ECGs.

V. CONCLUSÕES

Este trabalho envolveu a aplicação da teoria de análise de recorrência à classificação de sinais de ECGs da base MIT-BIH ARR. Avaliamos o desempenho de quatro classificadores (KNN, RF, MLP e ResNet) considerando as representações TS, SPGs, DPs e RPs dos ECGs.

Vimos que DPs têm um desempenho médio similar a SPGs e TS, com o benefício de ter uma dispersão consideravelmente menor. Além disso, concluímos que a binarização feita nos RPs não traz ganhos à classificação de ECGs e piora o desempenho de modelos não-profundos.

Como continuação deste trabalho, pretendemos incorporar técnicas de *data augmentation* para diversificar e ampliar a base, além de avaliar outros classificadores profundos e, por fim, aplicar técnicas de interpretabilidade para examinar os aspectos dos DPs/RPs que se mostram mais discriminativos.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP, Processo 2024/10715-1), dentro do contexto do BIOS - *Brazilian Institute of Data Science* (Processo 2020/09838-0), e do CNPq (308425/2023-5 e 313970/2023-8).

REFERÊNCIAS

- [1] SAÚDE, O. M. da. **em** Cardiovascular diseases (CVDs). 2024. [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)).
- [2] SAÚDE, O. P.-A. da Saúde e Organização Mundial da. **em** Doenças cardiovasculares. 2024. <https://www.paho.org/pt/topicos/doencas-cardiovasculares>.
- [3] MATHUNJWA, B. M. et al. Ecg arrhythmia classification by using a recurrence plot and convolutional neural network. **em** Biomedical Signal Processing and Control, Elsevier, v. 64, p. 102262, 2021.
- [4] GACEK, A.; PEDRYCZ, W. **em** ECG signal processing, classification and interpretation: a comprehensive framework of computational intelligence. [S.l.]: Springer Science & Business Media, 2011.
- [5] ALMAZAYDEH, L.; ELLEITHY, K.; FAEZIPOUR, M. Detection of obstructive sleep apnea through ecg signal features. In: IEEE. **em** 2012 IEEE International Conference on Electro/Information Technology. [S.l.], 2012. p. 1–6.
- [6] LUZ, E. J. d. S. et al. Ecg-based heartbeat classification for arrhythmia detection: A survey. **em** Computer methods and programs in biomedicine, Elsevier, v. 127, p. 144–164, 2016.
- [7] BONG, S. Z.; MURUGAPPAN, M.; YAACOB, S. Analysis of electrocardiogram (ecg) signals for human emotional stress classification. In: **em** Proceedings of the First International Conference on Trends in IRAM 2012. Kuala Lumpur, Malaysia: Springer, 2012. p. 198–205.
- [8] HUSSEIN, A. F. et al. Performance evaluation of time-frequency distributions for ecg signal analysis. **em** Journal of medical systems, Springer, v. 42, p. 1–16, 2018.
- [9] VENKATESAN, C.; KARTHIGAİKUMAR, P.; VARATHARAJAN, R. A novel lms algorithm for ecg signal preprocessing and knn classifier based abnormality detection. **em** Multimedia Tools and Applications, Springer, v. 77, p. 10365–10374, 2018.
- [10] MOODY, G. B.; MARK, R. G. The mit-bih arrhythmia database on cd-rom and software for use with it. In: IEEE. **em** [1990] Proceedings Computers in Cardiology. [S.l.], 1990. p. 185–188.
- [11] KUMAR, D. Y. S. K. R. G. Investigating cardiac arrhythmia in ecg using random forest classification. **em** International Journal of Computer Applications, Foundation of Computer Science (FCS), NY, USA, New York, USA, v. 37, n. 4, p. 31–34, January 2012. ISSN 0975-8887. Disponível em: <<https://ijcaonline.org/archives/volume37/number4/4599-6557/>>.
- [12] SANNINO, G.; PIETRO, G. D. A deep learning approach for ecg-based heartbeat classification for arrhythmia detection. **em** Future Generation Computer Systems, Elsevier, v. 86, p. 446–455, 2018.
- [13] BRITO, C.; MACHADO, A.; SOUSA, A. Electrocardiogram beat-classification based on a resnet network. In: **em** MEDINFO 2019: Health and Wellbeing e-Networks for All. [S.l.]: IOS Press, 2019. p. 55–59.
- [14] ALMEIDA, T. P. et al. Characterization of human persistent atrial fibrillation electrograms using recurrence quantification analysis. **em** Chaos: An Interdisciplinary Journal of Nonlinear Science, AIP Publishing, v. 28, n. 8, 2018.
- [15] GORDON, D. et al. Searching for “order” in atrial fibrillation using electrogram morphology recurrence plots. **em** Computers in biology and medicine, Elsevier, v. 65, p. 220–228, 2015.
- [16] LUONGO, G. et al. Hybrid machine learning to localize atrial flutter substrates using the surface 12-lead electrocardiogram. **em** EP Europace, Oxford University Press, v. 24, n. 7, p. 1186–1194, 2022. Disponível em: <<https://academic.oup.com/europace/article/24/7/1186/6511676>>.
- [17] YANG, H. Multiscale recurrence quantification analysis of spatial cardiac vectorcardiogram signals. **em** IEEE Transactions on Biomedical Engineering, IEEE, v. 58, n. 2, p. 339–347, 2010.
- [18] ECKMANN, J.-P.; KAMPHORST, S. O.; RUELLE, D. Recurrence plots of dynamical systems. **em** World Scientific Series on Nonlinear Science Series A, World Scientific Publishing, v. 16, p. 441–446, 1995.
- [19] MARWAN, N. et al. Recurrence plots for the analysis of complex systems. **em** Physics reports, Elsevier, v. 438, n. 5-6, p. 237–329, 2007.
- [20] MINKOWSKI, H. Ueber geometrie der zahlen. **em** Jahresbericht der Deutschen Mathematiker-Vereinigung, v. 1, p. 64–65, 1891. Disponível em: <<http://eudml.org/doc/144378>>.
- [21] GOLDBERGER, A. L. et al. Physiobank, physiotoolkit, and physionet: components of a new research resource for complex physiologic signals. **em** circulation, Am Heart Assoc, v. 101, n. 23, p. e215–e220, 2000.
- [22] SU, L.; BOROV, S.; ZRENNER, B. 12-lead holter electrocardiography: Review of the literature and clinical application update. **em** Herzschritt-machertherapie+ Elektrophysiologie, Springer, v. 24, p. 92–96, 2013.
- [23] Association for the Advancement of Medical Instrumentation (AAMI) and American National Standards Institute (ANSI). **em** Testing and reporting performance results of cardiac rhythm and ST segment measurement algorithms. [S.l.], 2008.
- [24] CHAZAL, P. D.; O'DWYER, M.; REILLY, R. B. Automatic classification of heartbeats using ecg morphology and heartbeat interval features. **em** IEEE transactions on biomedical engineering, IEEE, v. 51, n. 7, p. 1196–1206, 2004.
- [25] LUO, S.; JOHNSTON, P. A review of electrocardiogram filtering. **em** Journal of electrocardiology, Elsevier, v. 43, n. 6, p. 486–496, 2010.
- [26] TAKENS, F. Detecting strange attractors in turbulence. In: RAND, D. A.; YOUNG, L.-S. (Ed.). **em** Dynamical Systems and Turbulence, Warwick 1980. [S.l.]: Springer, 1981, (Lecture Notes in Mathematics, v. 898). p. 366–381.
- [27] MARWAN, N. How to avoid potential pitfalls in recurrence plot based data analysis. **em** International Journal of Bifurcation and Chaos, World Scientific, v. 21, n. 04, p. 1003–1017, 2011.