



EXTRAÇÃO DE CARACTERÍSTICAS COM ESTATÍSTICAS DE ALTA ORDEM PARA CLASSIFICAÇÃO DE FIBRILAÇÃO ATRIAL PAROXÍSTICA E RITMO SINUSAL NORMAL UTILIZANDO APRENDIZADO DE MÁQUINA

Luís Fillype da Silva*¹, Jonathan Araújo Queiroz¹, Allan Kardec Barros¹

¹UFMA – Universidade Federal do Maranhão

Resumo - O eletrocardiograma (ECG) é um procedimento simples e rotineiro de grande importância para diagnósticos de patologias cardíacas. Este procedimento corresponde a uma representação gráfica da atividade elétrica do coração, que resulta na sua interpretação por apresentar ondas, segmentos e intervalos possíveis de medição e identificação de alterações presentes no órgão cardíaco. Este artigo tem como objetivo desenvolver um modelo de classificação baseado nos batimentos de dois grupos de indivíduos: com Fibrilação atrial Paroxística e Ritmo sinusal normal. A metodologia de extração de características baseada e adaptada para classificar indivíduos com Fibrilação Atrial paroxística e saudáveis. As classificações foram realizadas baseadas nas características das estatísticas das duas base de dados, avaliando as métricas dos algoritmos K-nearest Neighbors (KNN), e Support vector Machine (SVM), obtendo acurácia de 90% a 100%.

Palavras-Chave – Extração de características, Aprendizado de Máquina, ECG, Estatísticas de Alta Ordem, KNN, SVM.

FEATURE EXTRACTION WITH HIGH ORDER STATISTICS FOR CLASSIFICATION OF PAROXISTIC ATRIAL FIBRILLATION AND NORMAL SINUS RHYTHM USING MACHINE LEARNING

Abstract - The electrocardiogram (ECG) is a simple and routine procedure of great importance for diagnosing cardiac pathologies. This procedure corresponds to a graphic representation of the electrical activity of the heart, which results in its interpretation as it presents waves, segments and possible intervals of measurement and identification of changes present in the cardiac organ. This article aims to develop a classification model based on the beats of two groups of individuals: with Paroxysmal Atrial Fibrillation and Normal sinus rhythm. The methodology of features extraction is based and adapted to classify individuals with paroxysmal Atrial Fibrillation

and healthy. The classifications were performed based on the characteristics of the statistics of the two databases, evaluating the metrics of the algorithms K-nearest Neighbors (KNN), and Support vector Machine (SVM), obtaining accuracy from 90% to 100%.

Keywords – Feature extraction, Machine Learning, ECG, High Order Statistics, KNN, SVM.

I. INTRODUÇÃO

De acordo com pesquisas realizadas pela Organização Mundial da Saúde (OMS) [1], estima-se que 17 milhões de pessoas em todo o mundo são vítimas de doenças cardíacas a cada ano. No Brasil, este número equivale a cerca de 1000 pessoas que diariamente morrem por esta cardiopatia. Desta maneira, faz-se necessário uma metodologia de diagnóstico eficaz das doenças cardíacas, impulsionando o desenvolvimento de métodos autônomos que auxiliam na detecção dessas cardiopatias. Um exame que quantifica a atividade elétrica do coração, possibilitando detectar a frequência cardíaca e o número de batimentos por minuto, é a análise do eletrocardiograma (ECG). Sendo assim, o ECG é essencial para prever, detectar e diagnosticar diversos problemas cardíacos, como a fibrilação atrial, por ser uma das técnicas não invasivas mais utilizadas para auxiliar nesse diagnóstico [4]. Trabalhos como o de Kachuee et al. [2] propõem um método baseado em redes neurais convolucionais profundas para a classificação dos batimentos cardíacos, capaz de classificar com precisão cinco diferentes arritmias. Ullah et al. [3] realizam uma classificação de 8 tipos de arritmia também utilizando redes neurais convolucionais. Já em Queiroz et al. [4] é estudado a variabilidade dos batimentos cardíacos e provê um método de diagnóstico automático de cardiopatia.

Este artigo se propõe a extrair todo o batimento cardíaco de todos os ECG das bases utilizadas, de forma a agrupar dois grupos, indivíduos com sinais de Fibrilação Atrial Paroxística (FAP) e com o Ritmo Sinusal Normal. Esta etapa será realizada utilizando Estatísticas de alta ordem, que são utilizadas para medir além da variância, outras variáveis que caracterizem uma distribuição dos dados. Posteriormente,

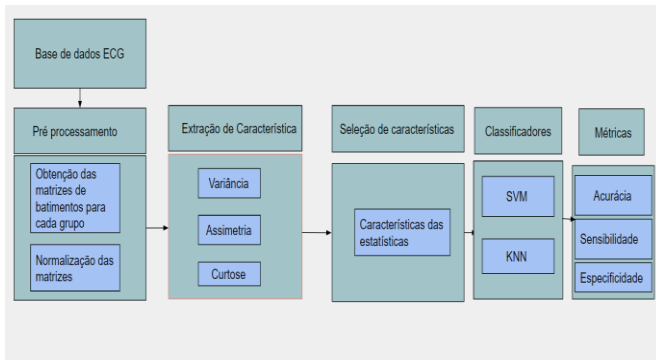
*silvaluis_@outlook.com

estas características extraídas serão aprendidas por classificadores de Aprendizado de Máquina.

II. MATERIAIS E MÉTODOS

Na Figura 1, a metodologia utilizada neste artigo é ilustrada. As bases de dados a serem utilizadas foram definidas, separando-as em dois grupos: sinais de indivíduos com FAP e indivíduos com ritmo sinusal normal. Foi realizado o pré-processamento dos sinais do banco de dados, organizando-os para a extração das características. Nesta etapa, são calculados os valores de variância, assimetria e curtose do conjunto de dados de cada base.

Figura 1: Metodologia proposta para a realização do trabalho.



1. A. Base de dados

Os banco de dados utilizados foram o The MIT-BIH Normal Sinus Rhythm Database e o Long Term Atrial Fibrillation Database, ambas disponíveis em [5][6]. O banco de pacientes com ritmo sinusal normal contém 18 registros, e destes foram utilizados 13 para esta análise. Já a base de dados de pacientes com fibrilação atrial paroxística, tirados de ECG a longo prazo, contém 75 pacientes, sendo destes utilizados 20.

De ambas as bases, foram selecionados os sinais de ECG característicos da derivação DII. Foram selecionados toda a duração do sinal, amostrados a uma frequência de 256 Hz para extração dos batimentos.

2. B. Pré processamento

Para cada base de dados, foram selecionados a derivação DII do ECG de cada paciente, para análise e a posterior extração de características. Após isso, segmentou-se cada sinal selecionados de forma a obter todo o respectivo batimento.

Agrupou-se os batimentos de cada grupo, sendo gerada uma matriz A pela concatenação dos batimentos do grupo saudável, e uma matriz B de batimentos do grupo com Fibrilação Atrial paroxística, como descrito na Equação 1 abaixo.

$$Bn, m = [Bn, a \quad Bn, b \quad \dots \quad Bn, z] \quad (1)$$

Onde:

- n - Número de batimentos.
- m - Número de colunas.
- B - Matriz que contém os batimentos concatenados.

Após o agrupamento, realizou-se a subtração do conjunto obtido pela média, dividindo pela entropia de Shannon do sinal, segundo a Equação 2.

$$Bn, m = \frac{Bn, m - \frac{1}{N} \sum_1^N Bn, m}{-\sum_1^n Pn, m (\log_2 \frac{1}{Pn, m})} \quad (2)$$

Onde:

- P - Probabilidade associada a cada batimento.
- B - Matriz de batimentos da classe.

C. Extração de características

Nesta etapa, utilizou a metodologia de extração por meio de estatística de alta ordem, até a quarta, proposta em [4]. Por meio das equações a serem descritas abaixo, obteve-se um vetor para cada uma das estatísticas associadas: variância, curtose e assimetria. As Equações 3, 4 e 5 representam-nas, respectivamente:

$$\sigma_x^2 = E(X^2) - ((E(X))^2) \quad (3)$$

Onde:

- σ_x^2 - Variância.
- $E(X)$ - Os valores esperados de X.

$$\lambda_x = E[(X - E(X))\sigma^{-1}]^3 \quad (4)$$

Onde:

- λ_x - Assimetria.
- $E(X)$ - Os valores esperados de X.

$$\kappa_x = E[(X - E(X))\sigma^{-1}]^4 \quad (5)$$

Onde:

- κ_x - Curtose.
- $E(X)$ - Os valores esperados de X.

D. Métricas de avaliação

Foram usadas como métrica de avaliação para os classificadores os valores de acurácia, sensibilidade e especificidade, descritos pelas equações abaixo.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \times 100 \quad (6)$$

$$Sensibilidade = \frac{VP}{VP + FN} \times 100 \quad (7)$$

$$Especificidade = \frac{VN}{VN + FP} \times 100 \quad (8)$$

Onde:

- VP - verdadeiros positivos.
- VN - verdadeiros negativos.
- FP - falso positivos.
- FN - falso negativos.

III. RESULTADOS

Este artigo analisou os batimentos extraídos do ECG para pacientes com FA paroxística e de sinais de indivíduos com Ritmo sinusal normal, a fim de classificá-los. Para a etapa de classificação, foram geradas matrizes, onde cada coluna é representada por variância, assimetria e curtose, respectivamente. Tais matrizes foram as entradas dos classificadores KNN e SVM para verificar qual algoritmo de classificação apresenta maior acurácia, sensibilidade e especificidade.

Além disso, foi realizada a comparação dos resultados com duas dimensões nos conjuntos de dados (σ_X^2 e κ_X) e com (σ_X^2 e λ_X). Já com três dimensões utilizou-se (σ_X^2 , λ_X e κ_X). Os resultados estão expostos na Tabela I, Tabela II e Tabela III.

Tabela 1: Métricas de avaliação com Variância x Curtose

Estatísticas	KNN	SVM
Acurácia	80%.	100%.
Sensibilidade	85%.	100%.
Especificidade	71.67%.	100%.

Tabela 2: Métricas de avaliação com Variância x Assimetria x Curtose

Estatísticas	KNN	SVM
Acurácia	89%.	100%.
Sensibilidade	91%.	100%.
Especificidade	90.7%.	100%.

Tabela 3: Métricas de avaliação com Variância x Assimetria

Estatísticas	KNN	SVM
Acurácia	72%.	98%.
Sensibilidade	78%.	97.5%.
Especificidade	78.77%.	99.1%.

IV. DISCUSSÕES

Este trabalho apresenta análises das características em duas e três dimensões. Vale a pena ressaltar que nos trabalhos de Kachuee et al. [2] e Hullah et al. [3], foram utilizadas mais de 2 cardiopatias, resultando num modelo robusto e complexo. Dicotomicamente analisando, como neste trabalho, os resultados foram satisfatórios, alcançando valores acima de 90% de acurácia. Já em [8], encontra-se um método de extração de característica baseado em Estatísticas de Alta

Ordem dos coeficientes Wavelets, alcançando também resultados acima de 90%.

No que tange aos resultados deste artigo, como pode-se observar na Figura 2, a análise em duas dimensões mostra uma boa separação dos dados utilizando variância e curtose, reafirmando os resultados expostos em [4] e em [7], que apontam que a curtose pode ser uma abordagem apropriada para medir sinais esparsos, como ECG. Já na Figura 3, utilizando a variância e a assimetria dos dados, pode-se obter uma separação melhor. Porém, no intervalo de valores entre 0.002 e 0.0003 apresentam valores que podem representar outliers no modelo.

Observou-se que combinações que utilizam a variância e curtose em suas representações de características obtiveram maior separação entre os dois grupos. Isso porque ECG de indivíduos com fibrilação atrial têm a variância maior, enquanto os indivíduos com o ritmo sinusal normal têm uma menor variância nos dados. Na Figura 4, mostra-se uma representação tridimensional, levando em consideração a variância, a assimetria e a curtose do conjunto de batimentos de cada grupo.

Figura 2: Variância x Curtose.

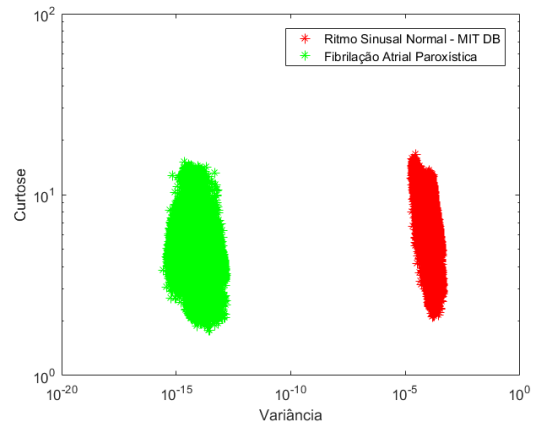


Figura 3: Variância x Assimetria.

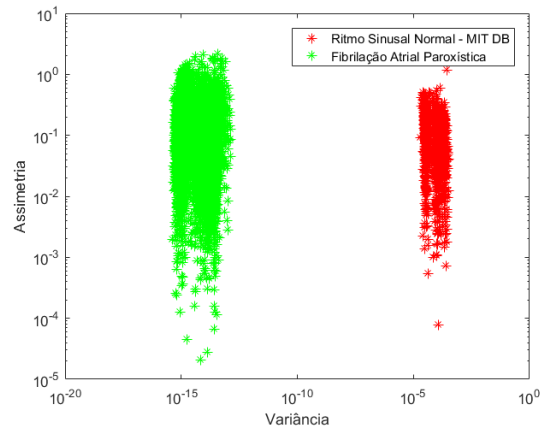
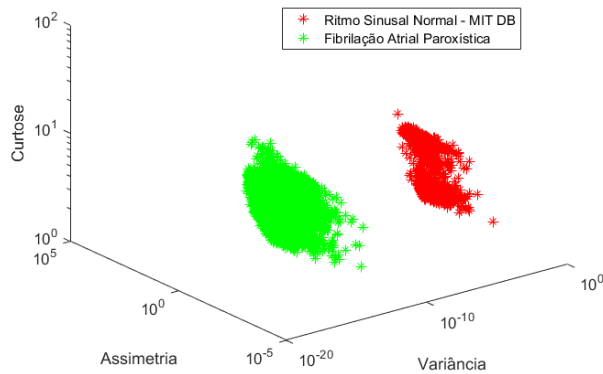


Figura 4: Variância x Assimetria x Curtose.



O SVM teve melhor desempenho devido a sua facilidade de definição de parâmetros para obtenção da melhor acurácia. Já o KNN, por ter um treinamento lento e também ser necessário a estimação do número de K, esse algoritmo teve um desempenho abaixo do SVM.

V. CONCLUSÕES

O método proposto reforça outros estudos que mostram a eficácia da utilização de estatísticas de alta ordem para extração de características e classificação de cardiopatias como a fibrilação atrial paroxística. Também pode-se inferir que os resultados obtidos pelo método presente neste artigo podem ser utilizados para auxiliar a tomada de decisão em processos clínicos, além de detectar arritmias autonomamente.

Em trabalhos futuros, diferentes cardiopatias e técnicas podem ser usadas para melhorar o pré processamento, bem como aplicar outros classificadores para avaliação das métricas, fazendo alternância de parâmetros para verificar quais obtêm uma maior acurácia. Pode-se também analisar outras ondas do coração, além dos batimentos, aplicando a metodologia utilizada para verificar e comparar com os resultados deste artigo.

AGRADECIMENTOS

Agradecemos o laboratório de Processamento da Informação Biológica da Universidade Federal do Maranhão pelo apoio à pesquisa realizada, e ao CNPQ pelo fomento disponibilizado.

REFERÊNCIAS

- [1] World Health Organization (2020). Cardiovascular diseases. Acedido em 17 de Setembro de 2020, em: <https://www.who.int/health-topics/cardiovascular-diseases>.
- [2] M. Kachuee, S. Fazeli and M. Sarrafzadeh, "ECG Heartbeat Classification: A Deep Transferable Representation," 2018 IEEE International Conference on Healthcare Informatics (ICHI), New York, NY, 2018, pp.

- 443-444. Acedido em 18 de Setembro de 2020, em: <https://arxiv.org/pdf/1805.00794.pdf>.
- [3] A. U. S. M. M. B. RM; "Classification of Arrhythmia by Using Deep Learning with 2-D ECG Spectral Image Representation" Remote Sensing. 2020. Acedido em 18 de Setembro de 2020, em <https://arxiv.org/pdf/1805.00794.pdf>
- [4] Q. J. A. J. A. L. F. B. AK; "Diagnostic decision support systems for atrial fibrillation based on a novel electrocardiogram approach," Journal of electrocardiology. 2017. Acedido em 18 de Setembro de 2020, em <https://pubmed.ncbi.nlm.nih.gov/29187299/>.
- [5] G. A. A. L. G. L. H. J. I. P. C. MR; "The Long-Term Atrial Fibrillation Database". PhysioBank, PhysioToolkit, and PhysioNet. Acedido em 14 de Setembro de 2020, em: <https://archive.physionet.org/physiobank/database/ltafdb/>
- [6] G. A. A. L. G. L. H. J. I. P. C. MR; "The MIT-BIH Normal Sinus Rhythm Database". PhysioBank, PhysioToolkit, and PhysioNet. Acedido em 14 de Setembro de 2020, em: <https://archive.physionet.org/physiobank/database/nsrdb/>
- [7] L. F. A. K. J. P. O. N. "Statistical coding and decoding of heartbeat intervals". PLoS One. 2011. Acedido em 19 de Setembro de 2020, em: https://www.researchgate.net/publication/51239927_Statistical_Coding_and_Decoding_of_Heartbeat_Intervals.
- [8] Y. Kutlu and D. Kuntalp, " Feature extraction for ECG heartbeats using higher order statistics of WPD coefficients," 2012 Comput Methods Programs Biomed , 2012. Acedido em 18 de Setembro de 2020, em: <https://pubmed.ncbi.nlm.nih.gov/22055998/>.