



Classificação de Arritmias com Paradigma Inter e Intra Paciente utilizando Aprendizagem Profunda

Classification of Arrhythmias with Inter and Intra Patient Paradigms Using Deep Learning

Clasificación Inter y Intrapaciente de Arritmias con Redes Neuronales Profundas

Sthefanie Jofer Gomes Passo¹, Hygo Sousa de Oliveira², Rafael Albuquerque Pinto², Kevin Gustavo Montero Quispe³, Rafael Gusti⁴, Eduardo James Pereira Souto⁴

RESUMO

Descritores: Redes Neurais; Arritmias Cardíacas; Eletrocardiograma

Objetivo: Classificar arritmias cardíacas conforme a morfologia do sinal no eletrocardiograma (ECG), utilizando métodos de aprendizagem de máquina profunda. **Método:** Dois níveis hierárquicos para classificação são propostos, o primeiro nível classifica batimentos normais e anormais, e o segundo nível trata do problema de multi-classificação entre classes dos batimentos anormais. O classificador é uma arquitetura de rede neural convolucional (CNN) aplicado para extração de características e classificação do sinal ECG. **Resultados:** A avaliação do método é realizada sobre a base MIT conforme os paradigmas intra e inter-paciente, cuja acurácia média de cada um é de 98,52% e 90,39%, respectivamente. **Conclusão:** O método hierárquico apresenta melhorias na classificação de arritmias cardíacas com destaque nas classes minoritárias em ambos os paradigmas.

ABSTRACT

Keywords: Neural Networks; Cardiac Arrhythmias; Electrocardiogram

Objective: Classification of cardiac arrhythmia from the morphology of an electrocardiogram signal (ECG) using Deep Learning techniques. **Method:** We propose a two-level hierarchical classifier. The first level classifies normal and abnormal heartbeats, and the second deals with the multi class identification of the abnormal beats. The classifier is a convolutional neural network architecture (CNN) employed in feature extraction and classification of ECG signal. **Results:** The method was evaluated on the MIT dataset on the intra-patient and inter-patient paradigms, achieving average accuracy of 98.52% and 90.39%, respectively. **Conclusion:** The hierarchical method shows improvement on the classification of cardiac arrhythmia, especially on the minority classes, in both paradigms.

RESUMEN

Descriptores: Redes Neurales; Arritmias Cardíacas; Electrocardiograma

Objetivo: Clasificar las arritmias cardíacas de acuerdo con la morfología de la señal en el electrocardiograma (ECG), utilizando métodos de aprendizaje automático profundo. **Método:** Proponemos un clasificador jerárquico de dos niveles. El primer nivel clasifica los latidos cardíacos normales y anormales, y el segundo se ocupa del problema de la clasificación múltiple entre clases de latidos anormales. El clasificador es una arquitectura de red neuronal convolucional (CNN) aplicada en la extracción de características y clasificación de la señal de ECG. **Resultados:** El método se evaluó en el conjunto de datos MIT en los paradigmas intra e interpaciente, logrando una precisión promedio de 98,52% y 90,39%, respectivamente. **Conclusión:** El método jerárquico muestra mejoras en la clasificación de las arritmias cardíacas, especialmente en las clases minoritarias, en ambos paradigmas.

¹ Discente de Graduação do curso de Engenharia de Software no Instituto de Computação, Universidade Federal do Amazonas – UFAM, Manaus (AM), Brasil.

² Discente de Mestrado em Informática, Universidade Federal do Amazonas (UFAM), Manaus (AM), Brasil.

³ Discente de Doutorado em Informática, Universidade Federal do Amazonas (UFAM), Manaus (AM), Brasil.

⁴ Professor Associado do Instituto de Computação, Universidade Federal do Amazonas (UFAM), Manaus (AM), Brasil.

INTRODUÇÃO

Arritmia cardíaca é um estado identificado por anormalidades ou falta de ritmo nos batimentos do coração⁽¹⁾. Segundo a Sociedade Brasileira de Arritmias Cardíacas⁽²⁾, somente um tipo de arritmia cardíaca, a fibrilação atrial, atinge em torno de 175 milhões de pessoas no mundo e de 2 milhões no Brasil. Nos Estados Unidos, arritmias são responsáveis por mais de 750 mil hospitalizações todos os anos, tornando-se a doença com a maior taxa de mortalidade no decorrer das duas últimas décadas⁽³⁾.

Em um cenário ideal, um paciente deve ser notificado assim que uma anomalia for detectada e, dessa forma, encaminhado para realizar um tratamento médico adequado, reduzindo os riscos à vida⁽⁴⁾. No entanto, a maioria das pessoas detecta anomalias cardíacas somente quando o quadro da doença já está avançado, o que traz complicações e pode resultar em um tratamento ineficiente.

Evidências experimentais⁽⁵⁻⁶⁾ mostram que as doenças cardíacas poderiam ser diagnosticadas antecipadamente, controladas e prevenidas com o auxílio do monitoramento contínuo, principalmente dos sinais do eletrocardiograma (ECG). Os sistemas de monitoramento ECG captam um sinal fisiológico não estacionário formado por uma sequência de ondas que refletem a atividade elétrica do coração⁽⁷⁾. A Figura 1 ilustra um sinal ECG formado por duas ondas P, dois complexos QRS e por duas ondas T. Uma das características deste sinal corresponde a despolarização ventricular¹, padrão morfológico denominado na literatura como complexo QRS, no qual sua análise permite detectar e classificar sinais arritmicos⁽⁸⁻⁹⁾.

A detecção e classificação automática de sinais arritmicos a partir de sinais ECG têm sido abordadas na literatura usando métodos de aprendizagem de máquina⁽¹¹⁾. Redes Neurais Profundas (DNN)⁽¹²⁾, Redes Neurais Convolucionais (CNN)⁽¹³⁻¹⁴⁾ e Redes Neurais Recorrentes (RNN)⁽¹⁾ são exemplos desses métodos aplicados para classificação de batimentos cardíacos normais, batimentos ventriculares e batimentos supraventriculares ou atriais⁽¹⁵⁾.

Embora esses métodos tenham apresentado melhorias para o desafio de classificação, os seguintes problemas são investigados neste trabalho: sensibilidade e precisão são baixas para as classes de batimentos que apresenta poucas amostras em relação às demais classes (desbalanceamento do conjunto de dados); e o paradigma de avaliação de

desempenho dos classificadores, que pode ser intra ou inter-paciente.

No paradigma intra-paciente^(1,12-13,16), os classificadores são treinados a partir de dados que incluem batimentos de todos os participantes do experimento, podendo haver amostras distintas de um mesmo paciente no treino e no teste. Já no paradigma inter-paciente⁽¹⁶⁾, os participantes são divididos em um conjunto de treino e outro de teste, de modo que dados de um mesmo paciente não ocorrem em ambos os conjuntos. Essa metodologia é útil para avaliar o grau de generalização do método e eliminar vieses causados pela similaridade de dados de um paciente no treino e no teste.

Motivado pelos problemas mencionados, este artigo propõe um método que aplica uma Rede Neural Convolucional para classificar arritmias cardíacas a partir do sinal ECG do paciente. Uma abordagem hierárquica em dois níveis de classificação é também avaliada com o objetivo de melhorar as taxas de acerto e sensibilidade das classes minoritárias. No primeiro nível batimentos são classificados em normais e anormais. No segundo nível são classificadas as diferentes arritmias como: batimento ectópico supraventricular, batimento ectópico ventricular, fusão de batimento ventricular e batimentos cardíacos sem diagnóstico presentes nos batimentos anormais. Além disso, os dois paradigmas de avaliação, intra e inter-paciente, são avaliados e comparados.

Trabalho Relacionados

Com o desenvolvimento de tecnologias de aprendizagem de máquina e a necessidade do monitoramento contínuo para a assistência médica, a classificação automática de arritmia cardíaca tornou-se um tópico de interesse⁽¹⁶⁾. Porém, a classificação de arritmia baseada em ECG normalmente enfrenta desafios como a variação das propriedades do sinal de ECG, pois dependem de diferentes fatores como idade, sexo, condições físicas e estilo de vida. Na tentativa de superar esses problemas, diferentes abordagens baseadas em técnicas de aprendizagem de máquina para a classificação do batimento cardíaco têm sido propostas^(1,12-14,16).

Wu et al.⁽¹⁶⁾ propõem a utilização de técnicas de aprendizado profundo por intermédio da estrutura da rede neural com camadas convolucionais para detecção de arritmias cardíacas utilizando sinais ECG. A base de dados de arritmia cardíaca MIT-BIH⁽⁹⁾ é utilizada para o treinamento e avaliação do modelo proposto no paradigma

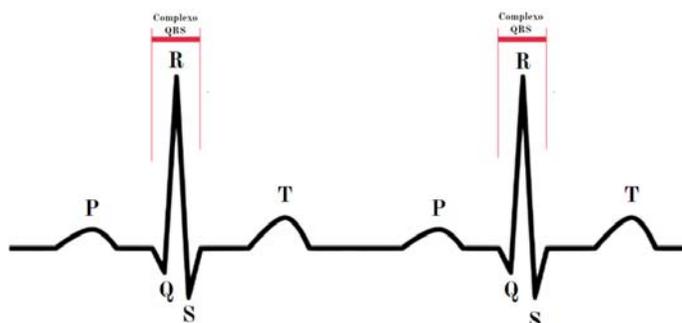


Figura 1 – Complexo QRS, ondas P, T⁽¹⁰⁾.

¹A despolarização ventricular é uma ativação atrial retrógrada, chamada de ecos atriais⁽²⁾.

inter-paciente. Experimentos são realizados com as seguintes classes: batimento normal (N), batimento ectópico supraventricular (S), batimento ventricular (V) e fusão de batimento ventricular (F). O modelo proposto atinge 94% de acurácia para classificação dos batimentos. Para a classe minoritária S, a sensibilidade e precisão são 96% e 45% e para a classe minoritária F, a sensibilidade e precisão são 93% e 35%.

Sannino⁽¹²⁾ propõe um método para a classificação binária de batimentos cardíacos normais e anormais, baseado em redes neurais profundas (DNN) com camadas totalmente conectadas. Esse método é composto pelas seguintes etapas: pré-processamento dos dados, detecção da onda P, Q e R, segmentação de dados e aplicação de uma DNN para classificação do batimento cardíaco. A base de dados MIT⁽⁹⁾ é utilizada na experimentação de acordo com o paradigma intra-paciente, tendo sido rotulada com batimentos normais e anormais. O método proposto atinge 99,09% de acurácia média, 98,55% de sensibilidade e 99,52% de especificidade.

Li et al.⁽¹⁾ propõem o uso de uma rede de memória longa-curto prazo bidirecional para melhorar a precisão na classificação dos batimentos cardíacos. O método consiste na aplicação de filtros para remoção de ruídos, extração de características (morfologia das ondas P, QRS, T e intervalo R-R) e do algoritmo de atenção, chamado BiLSTM-Attention. O classificador é treinado a partir dos dados da base MIT⁽⁹⁾, incluindo, além das cinco classes supracitadas, batimentos sem diagnóstico (classe Q). Os experimentos mostram que o classificador atinge 99,49% de acurácia. Para a classe minoritária S, a sensibilidade e precisão são 81,03% e 88,36% e para a classe minoritária F, a sensibilidade e precisão são 32,91% e 70,27%, respectivamente.

Kachuee et al.⁽¹³⁾ propõem um método baseado em CNN para classificar infarto do miocárdio com técnicas de transferência de aprendizagem^{II}. No método são utilizadas conexões residuais *skip* para transmitir conhecimento das primeiras camadas de convolução para as últimas. Na experimentação, o modelo é treinado utilizando a base MIT⁽⁹⁾ e um aumento de dados é aplicado para tratar o problema de desbalanceamento entre as classes N e as outras minoritárias (S, V, Q, F). Após seu treinamento, os pesos do modelo foram transferidos para um modelo de classificação binária de arritmias treinado com a base PTB Diagnostic ECG⁽¹⁷⁾. A avaliação intra-paciente do modelo treinado com a base MIT obteve uma acurácia de 93,4%; a classe minoritária S atingiu precisão de 89,00% e a classe minoritária F atingiu precisão de 86,00%. Na aplicação

da transferência de aprendizagem para classificar as classes Infarto do Miocárdio na base de dados PTB, o classificador atingiu acurácia de 95,90% e precisão de 95,20%.

Mousavi et al.⁽¹⁴⁾ propõem um sistema de classificação de arritmias cardíacas utilizando redes de memória de longo e curto prazo (LSTM) e redes neurais convolucionais, sendo avaliados em ambos os paradigmas, intra e inter-paciente. Devido ao desbalanceamento de dados da base do MIT⁽⁹⁾, os autores utilizaram a técnica de aumento de dados SMOTE nas classes minoritárias. Além disso, das 5 classes estabelecidas pela AAMI, no contexto intra-paciente são utilizadas apenas 4 classes (N, S, V, F), enquanto para o modelo inter-paciente são utilizadas apenas 3 (N, S, V). Os resultados de classificação, considerando a avaliação intra-paciente são de 99,92% de acurácia, 97% de sensibilidade média das duas menores classes (S e F) e 98,7% de precisão média; enquanto que a avaliação inter-paciente é de 99,53% de acurácia, 88,94% de sensibilidade para a classe minoritária S e 92,57% precisão.

Como observado nos trabalhos relacionados, redes neurais profundas e paradigmas de avaliação intra e inter-paciente são aplicados no problema de classificação de batimentos cardíacos. Devido à capacidade de aprender automaticamente características representativas dos sinais, as redes neurais profundas são utilizadas para aperfeiçoar a precisão na classificação, o que é um desafio devido às variações do sinal ECG entre indivíduos assim como demonstrado no trabalho de Mousavi et al.⁽¹⁴⁾ nos paradigmas intra e inter-paciente. A Tabela 1 apresenta um resumo das principais características utilizadas pelos trabalhos apresentados nesta seção, incluindo as bases de dados, número de classes, métodos adotados e acurácia do modelo proposto.

MÉTODO

Esta seção descreve o método proposto para a classificação automática de arritmias cardíacas. A Figura 2 ilustra o método composto por dois níveis hierárquicos para a classificação: o primeiro nível consiste no problema de classificação binária, considerando a classe de batimentos normais e as classes de batimentos anormais, enquanto o segundo nível trata do problema de multi-classificação entre as classes dos batimentos anormais.

Base de dados

Este trabalho utiliza a base de dados MIT-BIH⁽⁹⁾ de sinais ECG. A base é composta por 48 sinais ECG de 47

Tabela 1 – Resumo dos Trabalhos Relacionados.

Autor	Método	Base de Dados	Número de Classes	Paradigma de Avaliação	Acurácia
Wu et al., 2018	CNN	MIT	5	Intra-Paciente	93%
		DeepQ Arrhythmia	2		94%
Sannio, 2018	DNN	MIT	2	Intra-Paciente	100%
Li et al., 2019	Bi-LSTM	MIT	5	Intra-Paciente	99,49%
Kachuee et al., 2018	CNN	MIT	5	Intra-Paciente	93,4%
		PTB	2		95,9%
Mousavi et al., 2019	CNN	MIT	4	Intra-Paciente	99,92%
			3	Inter-Paciente	99,53%

^{II} A transferência de aprendizado correspondente a reutilização ou transferência de pesos de determinada camada neural previamente treinada para o aprendizado de uma nova tarefa⁽¹⁵⁾.

pacientes, rotulados com 5 tipos de batimentos cardíacos, conforme as recomendações de agrupamento das classes pela Associação para Instrumentação Médica Avançada (AAMI)⁽¹⁵⁾. Os batimentos são: batimento normal (N), batimento ectópico supraventricular (S), batimento ectópico ventricular (V), fusão de batimento ventricular (F) e batimentos cardíacos sem diagnóstico (Q). A base é particionada conforme o paradigma intra e inter-paciente. No paradigma intra-paciente, foi empregado o particionamento *holdout* com 80% dos dados para treino e 20% para teste. No paradigma inter-paciente os particionamentos de treino e teste foram formados por 37 indivíduos e 10 indivíduos, respectivamente.

Segmentação

Os dados ECG são segmentados com base em cada complexo QRS encontrado nos ciclos cardíacos. Ao verificar os ciclos é realizada a segmentação do sinal para alimentar o método proposto. De modo a garantir que exista um ciclo completo a partir da identificação do complexo QRS, é utilizada a estratégia de sobreposição com recuo e avanço em 5 segundos⁽¹³⁾, totalizando num segmento de 10 segundos de amostras ou 3600 amostras por segmento para a base do MIT⁽⁹⁾.

Extração de Características

Os segmentos do sinal ECG são passados como entrada para a rede neural, cuja estrutura é uma adaptação da rede neural U-Net⁽¹⁸⁾ para um problema de classificação de

arritmias cardíacas com base em sinais unidimensionais, utilizado originalmente para realização de segmentação semântica em imagens. A U-Net é uma rede com camadas de convolução dividida em dois blocos simétricos de codificação e decodificação. O bloco de codificação é responsável por extrair recursos espaciais que são utilizados pelo bloco de decodificação para realizar o mapeamento entre a entrada e saída da rede neural para a tarefa de classificação. Além dos blocos de codificação e decodificação, a rede U-Net possui conexões *skip* para preservar os mapas de recursos espaciais, que normalmente são perdidos durante as operações de agrupamento de características (*pooling*), ilustradas pelas setas na Figura 3.

No modelo de adaptação da arquitetura U-Net é adicionada a camada de normalização em lote (do inglês, *batch normalization*), garantindo estabilização nos ajustes dos parâmetros e reduzindo o tempo necessário para o treinamento. Todas as camadas convolucionais usam a função de ativação ReLU (*Rectified Linear Unit*) e são normalizadas por lote. Para produzir uma saída de classificação, a camada densa final usa uma função de ativação *sigmoid* para o seu primeiro nível hierárquico e a ativação probabilística *softmax* no segundo nível. Como a morfologia do sinal do batimento cardíaco varia de paciente para paciente, camadas *average pooling* são utilizadas para fazer uma média local de cada parte do sinal ECG corroborando na generalização ao reduzir a relevância de particularidades individuais de cada paciente.

O modelo é submetido a um treinamento com 1000

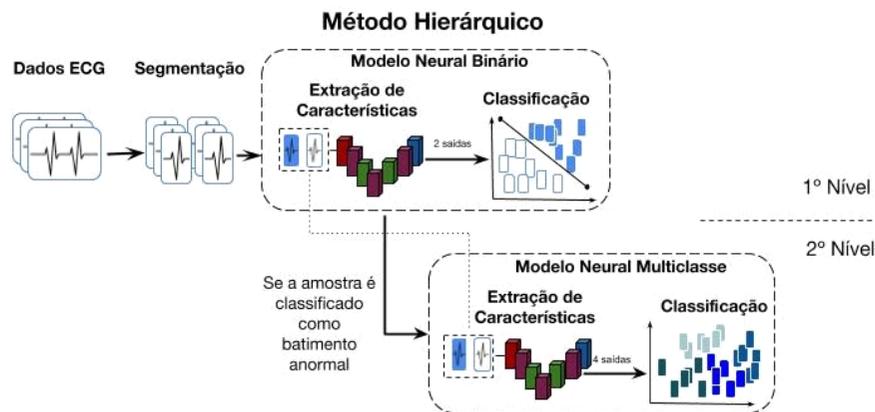


Figura 2 – Método hierárquico para analisar e classificar arritmias cardíacas com o ECG.

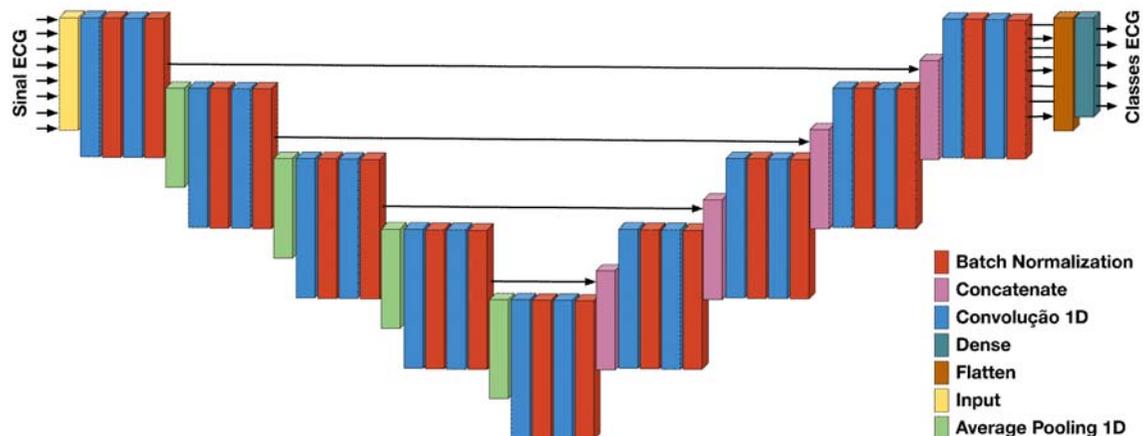


Figura 3 – Arquitetura do Modelo de Classificação de Arritmia Cardíaca.

épocas com monitores de convergência, como parada antecipada (*early stopping*) com espera em cinco épocas, redução da taxa de aprendizagem (*reduce learn rate on plateau*) com espera de duas épocas, e o ponto de checagem do modelo (*model check point*) para salvar apenas o modelo com melhor aprendizagem. Além disso, os hiperparâmetros são ajustados a partir de um *batch size* igual a 16 e 10% dos dados de validação.

Para a geração da arquitetura hierárquica proposta é aplicada a linguagem de programação *python* 3.6.9, sendo utilizadas as bibliotecas: *tensorflow* na versão 2.3.0 e *sklearn* na versão 0.22.2 durante o projeto. A rede é treinada no ambiente *Colaboratory* do Google utilizando uma Unidade de Processamento Gráfico em nuvem com capacidade de armazenamento de 25,52 GB de memória RAM e 68,40 GB de disco para *upload* dos dados ECG da base MIT.

Métricas de avaliação

O método proposto para a classificação de arritmia foi validado utilizando quatro métricas de avaliação: sensibilidade, precisão, especificidade e acurácia. A sensibilidade (*se*) refere a proporção de amostras verdadeiras positivas que são julgadas como positivas, quanto maior a sensibilidade maior é a proporção de predição. A precisão (*+p*) atesta que os valores preditivos positivos são realmente verdadeiros. A especificidade (*sp*) refere-se à proporção de amostras negativas que são julgadas como negativas. A acurácia (*Acc*) é a razão de amostras corretamente preditas. As fórmulas para calcular esses quatro indicadores de avaliação estão definidas a seguir:

$$se = \frac{TP}{TP+FN} \quad (1) \quad +p = \frac{TP}{TP+FP} \quad (2) \quad sp = \frac{TN}{TN+FP} \quad (3) \quad Acc = \frac{TP+TN}{TN+TP+FP+FN} \quad (4)$$

onde: verdadeiro positivo (TP) e verdadeiro negativo (TN) ocorrem quando os exemplos das duas classes são classificados corretamente, ao passo que falso positivo (FP) e falso negativo (FN) ocorrem quando os exemplos são classificados incorretamente. As medidas TP, FP, TN e FN podem ser observadas na matriz de confusão.

RESULTADOS E DISCUSSÃO

Para avaliação do método proposto, a implementação do método desenvolvido por Kachuee et al.⁽¹³⁾ (*baseline*) é submetida a experimentação para os dois paradigmas, intra e inter-paciente, e para as 5 classes de batimentos (N, S, V, F, Q). A escolha do *baseline* é justificada pela similaridade de técnicas aplicadas - redes neurais convolucionais com conexões skip - e por atingir as melhores taxas de precisão e sensibilidades para as classes minoritárias - S e F - entre os trabalhos revisados. Além disso Kachuee et al.⁽¹³⁾ utiliza todas as classes recomendadas pela AAMI, enquanto que Mousavi et al.⁽¹⁴⁾ utiliza somente parte delas em seus experimentos para treino de uma rede neural - LSTM - não similar da proposta no presente trabalho.

A Tabela 2 mostra os resultados da classificação de arritmias cardíacas utilizando o paradigma intra-paciente para a base de dados MIT. O método proposto em comparação com o *baseline* obteve uma melhoria de 7,55% na acurácia. Ao analisar os valores obtidos para as classes minoritárias S e F, melhorias na sensibilidade - 12,53% e 17,61% - e precisão - 21,81% e 50,00% - são observadas, respectivamente. A partir dos resultados obtidos, pode ser

Tabela 2 – Paradigma Intra-paciente: comparação do desempenho da classificação de batimento cardíaco do método proposto em relação ao baseline.

Método	Classe	TP	TN	FP	FN	Acc(%)	se(%)	sp(%)	+p(%)
Proposto	N	9006	2027	46	57	98,52	99,37	97,78	99,49
	S	237	10796	29	37		86,50	99,73	89,10
	V	668	10365	39	37		94,75	99,63	94,48
	F	52	10981	28	15		77,61	99,75	65,00
	Q	1070	9963	24	20		98,17	99,76	97,81
Baseline	N	8903	1274	149	817	90,87	91,59	89,53	98,35
	S	179	9998	87	63		73,97	99,14	67,29
	V	202	9975	505	64		75,94	95,18	28,57
	F	12	10165	68	8		60,00	99,34	15,00
	Q	881	9296	213	70		92,64	97,76	80,53

Tabela 3 – Paradigma Inter-paciente: comparação do desempenho da classificação de batimento cardíaco do método proposto em relação ao baseline.

Bases	Classe	TP	TN	FP	FN	Acc(%)	se(%)	sp(%)	+p(%)
Proposto	N	17701	3289	1409	633	90,39%	96,55	70,01	92,63
	S	164	20826	246	572		22,28	98,83	40,00
	V	501	20489	298	518		49,17	98,57	62,70
	F	0	20990	16	148		0,00	99,92	0,00
	Q	2624	18366	262	360		87,94	98,59	90,92
Baseline	N	11046	14	151	1615	86,12%	87,24	8,48	98,65
	S	0	11060	341	11		0,00	97,01	0,00
	V	0	11060	714	0		0,00	93,94	0,00
	F	0	11060	14	0		0,00	99,87	0,00
	Q	14	11046	562	156		8,24	95,16	2,43

visto claramente que classificação hierárquica ocasionou na melhoria da sensibilidade e precisão das classes minoritárias.

A Tabela 3 mostra os resultados da classificação de arritmias cardíacas utilizando o paradigma inter-paciente para a base de dados MIT. O método proposto em comparação com o *baseline* obteve uma melhoria de 4,27% na acurácia. Para a classe minoritária S é calculada uma melhoria, em relação ao *baseline*, de 22,28% precisão e 40,00% sensibilidade. Para classes F, o método proposto e o *baseline* mostram sensibilidade e precisão iguais a zero, pelo qual se conclui que a quantidade de amostras de treino dessa classe minoritária não foi suficiente para o aprendizado em ambos os classificadores.

Os resultados obtidos mostram que no paradigma intra-paciente a generalização dos dados em ambos os métodos têm um alto valor verdadeiro positivo devido aos conjuntos de treino e teste conterem dados de um mesmo indivíduo. No entanto, o paradigma inter-paciente apresenta uma generalização com menor precisão em relação ao intra-paciente, pois a variação da morfologia do sinal ECG geralmente varia bastante de indivíduo para indivíduo. Mesmo com essa limitação o método proposto alcançou valores de especificidade elevados para as classes N e Q. A maior diferença na aplicação dos paradigmas é a precisão e sensibilidade das classes minoritárias S e F, a qual reduz no mínimo 49,10% na avaliação intra-paciente em comparação com a avaliação inter-paciente. A discriminação das classes minoritárias no paradigma inter-paciente é um desafio para métodos profundos de aprendizagem de máquina.

REFERÊNCIAS

- Li, R., ZHANG, X., DAI, H., ZHOU, B., WANG, Z. Interpretability Analysis of Heartbeat Classification Based on Heartbeat Activity's Global Sequence Features and BiLSTM-Attention Neural Network. IEEE Access, Special Section on Scalable Deep Learning for Big Data. 2019.
- SOBRAC. Campanha coração na batida certa: Brasil em ação pela prevenção e tratamento das arritmias cardíacas e morte súbita [Internet]. Sociedade Brasileira de Arritmia Cardíaca. Available from: <https://sobrac.org/home/campanha-coracao-na-batida-certa-brasil-em-acao-pela-prevencao-e-tratamento-das-arritmias-cardiacas-e-morte-subia/>. 2020.
- AHRQ. (2012). Weighted national estimate. HCUP National Inpatient Sample. Agency for Healthcare Research and Quality. [Online] <https://www.ahrq.gov/>. Acesso em: 25/04/2019.
- CDC. CDC 24/7: Saving Lives, Protecting People. (2017). Centers for Disease Control and Prevention. [Online] <https://www.cdc.gov/>. Acesso em: 14/05/2020.
- Serhani, M.A.; T. El Kassabi, H.; Ismail, H.; Nujum Navaz, A. ECG Monitoring Systems: Review, Architecture, Processes, and Key Challenges. Sensors 2020, 20, 1796.
- Rosiek, A. e Leksowski, K. (2016). The risk factors and prevention of cardiovascular disease: the importance of electrocardiogram in the diagnosis and treatment of acute coronary syndrome. Therapeutics and Clinical Risk Management, Volume 12:1223–1229.
- Banerjee, R., et al. Photoecg: Photoplethysmography to estimate ecg parameters. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2014. pgs. 4404–4408.
- LAHRS. Recomendações para a medida do intervalo do QT durante o uso de medicamentos para o tratamento da infecção por COVID-19 [Internet]. Sociedade Latino-Americana do Ritmo Cardíaco. Available from: <https://sobrac.org/home/wp-content/uploads/2020/04/RECOMENDACOES-MEDIDA-INTERVALO-QT-COVID-19.pdf>. 2020.
- Goldberger A.L., et al. MIT-BIH Arrhythmia Database. PhysioNet. Available from: <https://physionet.org/content/mitdb/1.0.0/>. 2005. Version: 1.0.0.
- Tawakal I., Sauryana E., Noviyanto A. Analysis of multi codebook GLVQ versus standard GLVQ in discriminating sleep stages. Advanced Computer Science and Information Systems (ICACSIS), 2012.
- Bizopoulos P., Koutsouris D. Deep Learning in Cardiology. 1902.11122v1 [cs.CV]. IEEE. 2019.
- Sannino, G., Pietro, G. A deep learning approach for ECG-based heartbeat classification for arrhythmia detection. Future Generation Computer Systems. 2018.
- Kachuee, M., Fazeli, S., Sarrafzadeh, M. ECG Heartbeat Classification: A Deep Transferable Representation. University of California, Los Angeles (UCLA) Los Angeles, USA. 2018.
- Mousavi, S., Afghah, F., Acharya, U. Inter- and Intra-Patient ECG Heartbeat Classification For Arrhythmia Detection: A Sequence to Sequence Deep Learning Approach. School of Informatics, Computing and Cyber Systems, Northern Arizona University, Flagstaff, USA. 2019.
- AAMI. Association for the Advancement of Medical Instrumentation and American National Standards Institute, Testing and Reporting Performance Results of Cardiac Rhythm and ST-segment Measurement Algorithms [Internet]. Available from: <https://books.google.it/books?id=gzPdtgAACAAJ>. ANSI/AAMI, The Association, 2012. pp. 1–36.
- Wu M., Chang E., Chu T. Personalizing a Generic ECG Heartbeat Classification for Arrhythmia Detection: A Deep Learning Approach. IEEE Conference on Multimedia Information Processing and Retrieval. 2018.
- Goldberger A.L., et al. (2004) PTB Diagnostic ECG Database. PhysioNet. [Online] <https://www.physionet.org/content/ptbdb/1.0.0/>. Version: 1.0.0. Acesso em: 14/05/2020.

CONCLUSÃO

Este estudo propõe uma abordagem hierárquica em redes neurais convolucionais para classificação de arritmias cardíacas. Considerando o desbalanceamento de classes que geralmente existe em conjunto de dados coletados em cenários reais, a abordagem hierárquica para classificação melhora a precisão e sensibilidade das classes minoritárias. O desempenho do método proposto é avaliado com os paradigmas intra e inter-paciente, alcançando acurácias de 98,52% e 90,39%, respectivamente. Conforme os resultados, o método proposto apresentou melhorias na classificação de arritmias cardíacas com destaque nas classes minoritárias. As melhorias são o aumento da sensibilidade média de 23,82% e precisão média de 51,34% para as classes minoritárias S, V e F, no paradigma inter-paciente. Como trabalhos futuros é considerada a aplicação de técnicas de *data augmentation* para potencializar a generalização das classes minoritárias no paradigma inter-paciente.

AGRADECIMENTOS

Ao apoio financeiro do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), conforme previsto no Artigo 48 do Decreto nº 6.008 / 2006 (SUFRAMA), que foi financiada pela Samsung Eletrônica da Amazônia Ltda. nos termos da Lei Federal nº 8.387 / 1991 através do convênio 001/2020 firmado com a Universidade Federal do Amazonas (UFAM) e a Fundação de Amparo ao Ensino, Pesquisa, Extensão, e Interiorização do IFAM (FAEPI).