

Classificação Automática de ECG em Dispositivos Móveis

Jose Vigno Moura Sousa^{1,2}, Vilson Rosa de Almeida², Aratã Andrade Saraiva²,
Pedro Mateus Cunha Pimentel², Luciano Lopes de Sousa²

¹Universidade Brasil, Brasil

²Universidade Estadual do Piauí, Brasil

E-mail: josevigno@gmail.com

Resumo: Neste trabalho é proposto um novo método para classificar sinais de eletrocardiograma em dispositivos móveis que pode classificar diferentes arritmias de acordo com o padrão EC57 da *Association for the Advancement of Medical Instrumentation*. Uma rede neural convolucional foi construída, treinada e validada com o conjunto de dados de arritmia MIT-BIH, em que essa base de dados possui 5 classes diferentes: batimento normal, batimento supraventricular prematuro, contração ventricular prematura, fusão de batimento ventricular, normal e batimento inclassificável. Depois de treinado e validado, o modelo é submetido a um estágio de quantização pós-treinamento usando o método de conversão *TensorFlow Lite*. Os resultados obtidos foram satisfatórios, antes e após a quantização, a rede neural convolucional obteve uma acurácia de 98,5 %. Com a técnica de quantização foi possível obter uma redução significativa no tamanho do modelo, possibilitando assim o desenvolvimento do aplicativo móvel, essa redução foi de aproximadamente 90 % em relação ao tamanho do modelo original.

Palavras-chave: ECG, Quantização, CNN, Móvel.

Automatic ECG Classification on Mobile Devices

Abstract: In this work, a new method is proposed to classify electrocardiogram signals in mobile devices that can classify different arrhythmias according to the EC57 standard of the Association for the Advancement of Medical Instrumentation. A convolutional neural network was built, trained and validated with the MIT-BIH arrhythmia data set, in which this database has 5 different classes: normal beat, premature supraventricular beat, premature ventricular contraction, ventricular beat fusion, normal and unclassifiable beat. After being trained and validated, the model is submitted to a post-training quantization stage using the TensorFlow Lite conversion method. The results obtained were satisfactory, before and after quantization, the convolutional neural network obtained an accuracy of 98.5%. With the quantization technique it was possible to obtain a reduction in the size of the model, thus enabling the development of the mobile application, this reduction was approximately 90% in relation to the size of the original model.

Keywords: ECG, Quantization, CNN, Mobile.

Introdução

As doenças cardiovasculares são uma das principais causas de morte em todo o mundo. A morte súbita por arritmia cardíaca é um grande problema de saúde pública em todo o mundo, sendo responsável por 15% a 20% de todas as mortes [1].

No processo de detecção de anomalias cardíacas, o uso do eletrocardiograma (ECG) é um diagnóstico fundamental. No entanto, existem vários problemas com a análise manual de sinais de ECG, tais como: similaridade, dificuldade em detectar e categorizar diferentes formas de onda e morfologia do sinal. Para um ser humano, essa tarefa é demorada e sujeita a erros [2].

Os avanços tecnológicos e o aumento do poder computacional possibilitam o uso de técnicas que podem auxiliar no diagnóstico clínico, como exemplo, Redes Neurais Convolucionais (CNNs) [3]. Mas as CNNs exigem um alto custo computacional nos aplicativos finais, o que torna o desenvolvimento desses aplicativos uma tarefa desafiadora.

Este artigo apresenta um sistema de classificação de sinal de ECG móvel capaz de classificar diferentes arritmias de acordo com o padrão EC57 do *Advancement of Medical Instrumentation* (AAMI) [4]: batimento normal, batimento supraventricular prematuro, contração ventricular prematura, fusão de ventrículo e batimento normal, batimento inclassificável.

Para otimização de CNN, duas técnicas de quantização pós-treinamento são usadas, usando o método de conversão *TensorFlow Lite* (TFL) [5]. Esta técnica visa reduzir drasticamente o tamanho do modelo, consumo e processamento de energia, possibilitando o desenvolvimento de uma aplicação móvel utilizando CNN.

Objetivos

Propõe-se um sistema de classificação de sinal de ECG móvel capaz de classificar diferentes arritmias de acordo com o padrão EC57 do AAMI.

Material e Métodos

Esta seção apresenta os métodos usados para desenvolver aplicativos móveis, assim, como no diagrama ilustrado na Figura 1 mostra as principais partes constituintes do método.




Figura 1: Estrutura do sistema

Pré-processamento e divisão do conjunto de dados

Em todos os classificadores, o conjunto de dados foi dividido em validação e teste de treinamento, com 50% de cada classe de dados usada para treinamento, 25% usada para validação e 25% teste. Nem todos os sinais têm o mesmo comprimento, para tratar este problema do mesmo pré-processamento realizado por [4], as amostras são cortadas, reduzidas ou preenchidas com zeros, se necessário, para uma dimensão fixa de 187 valores.

Arquitetura e treinamento da CNN

Com isso, a rede proposta tem cinco blocos de convolução residual, em todas as camadas de convolução, a convolução 1D é aplicada e cada um tem um tamanho de *kernel* de tamanho 5, o *Pool* máximo com tamanho 5 e passa 2. Os melhores resultados de otimização para o número de O número de camadas conectadas era de 2 camadas com o número de 274 neurônios em cada camada, com a função de ativação *ReLU* e uma última camada de 5 neurônios, com uma taxa de aprendizagem de 0,00027 e o tamanho do lote de 128 amostras, a entrada A rede consiste em um vetor dimensional com 128 valores correspondentes a uma amostra de sinal de ECG.

Redes Neurais Quantizadas (QNN)

Redes Neurais Quantizadas usam ativações e pesos de baixa precisão. Essas redes são treinadas de zero a precisão de ponto fixo arbitrário. Onde em precisão, QNNs que usam menos bits requerem arquiteturas de rede mais profundas e mais amplas do que redes que usam operadores mais precisos, enquanto requerem aritmética menos complexa e menos bits por peso [6].

Desenvolvimento de aplicativos móveis

Todos os algoritmos foram desenvolvidos em *Python*, para implantação do CNN foi utilizada a *API TFL Java* [7], juntamente com os métodos de quantização utilizados, o que permite rodar um modelo *Tensorflow* em um dispositivo móvel utilizando a linguagem *Java*. A interface do aplicativo pode ser vista na figura 2.

Resultados e Discussões

Na literatura existem pesquisas com bons resultados para a classificação das arritmias utilizando o conjunto MIT-BIH. Porém para implantação em dispositivos móveis Android preconizam aspectos como uso de memória, processamento, tamanho do modelo final. Outro aspecto importante a ser considerado são as possibilidades de upgrades, ou seja, a resistência de um modelo escolhido ao acréscimo de outras classes.

Nas tabelas 3, 6 é possível visualizar a tabela com os resultados da validação para cada classe de arritmia. Dessa maneira, pode-se observar que a partir da tabela 5, contendo os resultados da quantização, é possível interpretar que poucos recursos são necessários para a implantação offline, porém é necessário estar atento a aspectos como frequência de chamadas para esses modelos, pois dependendo de outras funções embutidas no aplicativo, o processo pode ser torná-lo caro.

Tabela 1: Resultados obtido pelo modelo da rede neural na base de dados de validação

Classe	Precisão	ACC	Recall	F1	MCC	ROC
Batimento Normal	0.99	0.99	1.00	0.99	0.96	0.98
Batimento supraventricular prematuro	0.92	0.99	0.84	0.88	0.87	0.92
Contração ventricular prematura	0.97	1.00	0.96	0.96	0.96	0.98
Fusão de batimento ventricular e normal	0.84	1.00	0.73	0.78	0.78	0.87
Batida inclassificável	0.99	1.00	0.99	0.99	0.99	0.99
Média macro	0.94	0.99	0.99	0.92	0.91	0.95
Média micro	0.99	0.99	0.99	0.99	0.99	0.99

Dois métodos de quantização foram implementados: quantização da faixa dinâmica e quantização inteira, o tamanho do modelo antes da quantização é de 1,9 MB, com a quantização passou para 0,164 MB. Isso permite perceber uma redução significativa no tamanho do modelo de aproximadamente 90% de redução no tamanho do modelo. Dessa forma o uso de memória e processamento é otimizado.

Tabela 2: Descrição dos recursos de hardware usado para rodar as redes neurais.

Classificador	Use de memória RAM	Tempo de processamento	Uso médio do processador	Tamanho final	Perda de ACC
CNN com quantização dinâmica	3.3 MB	840 milissegundos	9%	0.164 MB	0.0%
CNN com quantização inteiro completo	3.4 MB	512 milissegundos	7%	0.175 MB	0.4%

De acordo com as Figuras 2 pode-se observar a interface e a tela inicial do aplicativo. O aplicativo possui uma interface simples e intuitiva para que sua utilização possa ser de fácil e ágil.




Figura 2: Exemplo da classificação do sinal de arritmia no dispositivo móvel.

Conclusões

Neste trabalho, é construída uma CNN que se mostrou eficiente, para validação dos resultados. Além disso, é proposta uma aplicação móvel capaz de classificar 5 tipos diferentes de batimentos cardíacos, sendo a primeira classe normal e as demais arritmias. Este método produziu resultados satisfatórios, com mais de 99,0% de macro precisão média.

Referências

1. Srinivasan, Neil T., and Richard J. Schilling. Sudden cardiac death and arrhythmias. *Arrhythmia & electrophysiology review* 7.2 (2018): 111.
2. Saraiva, A., Miranda de Jesus Castro, F., Ferreira, N., Valente, A.: Compression of electrocardiographs comparative study between the walsh hadamard transform and discrete cosine transform. (2018)
3. Saraiva, A., Ferreira, N., Sousa, L., Carvalho da Costa, N., Sousa, J., Santos, D., Soares, S.: Classification of images of childhood pneumonia using convolutional neural networks. In: 6th International Conference on Bioimaging, pp. 112–119 (2019)
4. Saraiva, A.A., Santos, D.B.S., Costa, N.J.C., Sousa, J.V.M., Ferreira, N.M.F., Valente, A., Soares, S.F.S.P.: Models of learning to classify x-ray images for the detection of pneumonia using neural networks. In: BIOIMAGING (2019)

5. Kachuee, M., Fazeli, S., Sarrafzadeh, M.: Ecg heartbeat classification: A deep transferable representation. In: 2018 IEEE International Conference on Healthcare Informatics (ICHI), pp. 443–444 (2018). IEEE
6. Moons, B., Goetschalckx, K., Van Berckelaer, N., Verhelst, M.: Minimum energy quantized neural networks. In: 2017 51st Asilomar Conference on Signals, Systems, and Computers, pp. 1921–1925 (2017). IEEE
7. Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., et al.: Tensorflow: A system for large-scale machine learning. In: 12th {USENIX} Symposium on Operating