

Utilização de Técnicas de Machine Learning para a Classificação de Sinais de Eletrocardiograma

Francisco E. de A. F. Júnior
Universidade Federal do Pará
Instituto de Tecnologia (ITEC)
jralbbuquerque@gmail.com

Sandio Maciel dos Santos
Universidade Federal do Pará
Instituto de Tecnologia (ITEC)
sandio.maciel@gmail.com

Marcelino Silva da Silva
Universidade Federal do Pará
Instituto de Tecnologia (ITEC)
marcelino@ufpa.br

João C. C. Carvalho
Universidade Federal do Pará
FACOMP Castanhal
joaochamma@ufpa.br

I. INTRODUÇÃO

De acordo com dados da Organização Mundial de Saúde, doenças cardiovasculares (DCVs) registram os maiores índices de causa morte no mundo, estima-se que aproximadamente 17,9 milhões pessoas morrem a cada ano devido a DCVs. Entretanto, avanços tecnológicos nas áreas da biologia e medicina, tem proporcionado o desenvolvimento de novas e mais eficientes ferramentas que auxiliam os profissionais dessas áreas em processos terapêuticos complexos e diagnósticos mais precisos. Diante desse cenário, esse trabalho propõe a utilização de *deep learning* para a classificação de sinais de eletrocardiograma (ECG) entre doentes e saudáveis, além de traçar um comparativo da sua eficiência em relação a uma *rede neural perceptron multicamada* (PMC).

II. METODOLOGIA

O processo metodológico para o desenvolvimento do estudo proposto foi sistematizado em três etapas. Primeiramente os sinais de ECG utilizados nesse experimento foram coletados no repositório do *PhysioNet*, selecionando 168 amostras, das quais 80 eram saudáveis e 88 possuíam algum tipo de arritmia cardíaca. Em seguida, foram extraídas características desses sinais para a confecção de uma base de dados. Por fim, foram desenvolvidas as técnicas de aprendizagem de máquinas propostas. Para avaliar a eficiência das redes neurais, optou-se por utilizar métricas de desempenho clássicas para modelos de classificação (acurácia, sensibilidade, precisão e *F-score*).

III. RESULTADOS, DISCUSSÕES E CONCLUSÃO

Foi realizada a avaliação dos modelos utilizando 70% dos dados como treinamento e 30% como teste. A Figura 1 ilustra o desempenho médio após 10 testes para ambas as técnicas. Evidencia-se a superioridade da *deep learning* em relação a PMC em todos os indicadores, destacando **95,88 %** de acerto médio da primeira contra 84,87 % da segunda. Além disso, destaca-se 99,41% de precisão da *deep learning* e a baixa sensibilidade da rede PMC (75,86%), possivelmente explicada pela pequena quantidade de dados utilizados no treinamento. Avaliando o *F-score* é possível verificar novamente uma superioridade da *deep learning* em relação a segunda técnica, apresentando resultados mais equilibrados perante a análise em questão. Dessa forma, nota-se que a *deep learning* pode ser uma importante alternativa para auxiliar profissionais da área em diagnósticos e quadros clínicos mais complexos.

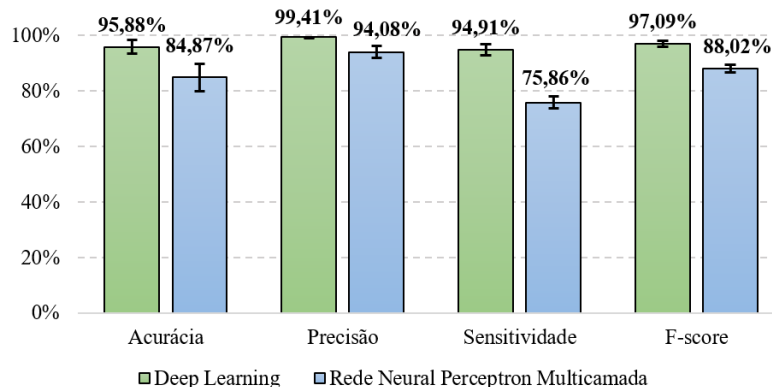


Figura 1 – Comparação do Desempenho das Técnicas de Aprendizagem de Máquina