

APRENDIZAGEM DE MÁQUINA APLICADA À ANÁLISE DE BATIMENTOS CARDÍACOS

Samuel A. Mezávila

samuelsezavila@gmail.com

Nykollas A. A. Dias

nicolauarti09@gmail.com

Matheus Eloy Franco

matheus.franco@ifsuldeminas.edu.br

Recebido em: 30/12/2021.

Aprovado em: 31/03/2023.



DOI: 10.18406/2359-1269v8n12021191



Resumo

A inserção da Inteligência Artificial (IA) nas atividades do dia a dia é uma realidade. Além das práticas cotidianas comuns, o aprendizado de máquina aplicado na medicina é importante, sendo uma das principais áreas de estudo da IA. Os diagnósticos médicos podem ser suportados com a utilização de algoritmos inteligentes, dada a rapidez e eficiência que podem proporcionar. Este artigo apresenta um estudo sobre a implementação de um algoritmo de aprendizado de máquina utilizando a linguagem Python para análise de eletrocardiograma, classificando o risco do paciente sofrer um infarto do miocárdio.

Palavras-chave: Inteligência artificial. Informática aplicada a saúde. Machine Learning.

Abstract

The insertion of Artificial Intelligence (AI) in day-to-day activities is a reality. In addition to common daily practices, machine learning applied in medicine is important, being one of the main areas of study for AI. Medical diagnoses can be supported with the use of intelligent algorithms, in view of the speed and efficiency they can provide. This article presents a study on the implementation of a machine learning algorithm using the Python language for electrocardiogram analysis, classifying the patient's risk of suffering a myocardial infarction.

Keywords: Artificial intelligence. Informatics applied to health. Machine Learning.

Introdução

No campo da inteligência artificial, as máquinas inteligentes, na maior parte dos anos, foram vistas como algo fora da realidade. Ainda não vemos “carros voadores”, mas dispositivos eletrônicos com capacidade de aprendizado já são realidade. Na medicina, a inserção da inteligência artificial é importante, tendo em vista que permite uma gama maior de possibilidades para tratamentos complexos. Diversas técnicas de aprendizagem de máquina foram desenvolvidas com objetivo de auxiliarem na previsão de doenças graves e ajudar no diagnóstico prematuro (SANTOS *et al.*, 2019).

Diante da importância da discussão do referido tema na atualidade, o presente trabalho realizou o estudo da aplicação de técnicas de aprendizagem de máquina para análises de exames de eletrocardiograma (ECG), a fim de auxiliar no diagnóstico do risco de infarto do miocárdio. Ressalta-se que a proposta não é um sistema médico, nem objetiva diagnosticar ou tratar quaisquer condições, tratando-se de um estudo que pode vir a auxiliar o diagnóstico cardíaco.

Referencial Teórico

Inteligência Artificial

Segundo Winston (1992), a Inteligência Artificial (IA) é o estudo do projeto de agentes inteligentes. As primeiras pesquisas de IA nos anos 1950 entraram em temas como a resolução de problemas, aprendizagem automática e redes neurais. Na década de 1960, a Defesa dos Estados Unidos se interessou por este tipo de tecnologia e começou a treinar computadores para imitar o raciocínio humano básico. A IA surgiu juntamente com a computação, Alan Turing, conhecido como o pai da computação, foi o primeiro na área da Inteligência Artificial, em que o desenvolvimento dela foi se aprimorando logo após o fim da Segunda Guerra Mundial. Alan Turing (1950) colocou em ordem uma hipótese de que a IA se tornaria uma realidade quando a comunicação entre o homem e máquina não distinguir a resposta humana e da máquina.

Pesquisadores como Anderson (2007) e Obermayer (2016) preveem que ferramentas de aprendizagem de máquina e inteligência artificial para analisar grandes quantidades de dados será um requisito fundamental para a nova geração de médicos, e que algoritmos e hardwares automatizados poderão substituir médicos algumas áreas.

A incorporação do aprendizado de máquina na medicina clínica promete melhorar substancialmente a prestação de cuidados de saúde. Empresas privadas estão correndo para construir o aprendizado de máquina na tomada de decisões médicas, seguindo ambas as ferramentas que suportam os médicos e os algoritmos projetados para funcionar independentemente deles (CHAR; SHAH; MAGNUS 2018).

A mente médica está se tornando a combinação de livros publicados na área e dados registrados nos sistemas de saúde, em oposição à experiência clínica individual de cada profissional (CHAR *et al.*, 2018). Embora essa mudança apresente oportunidades estimulantes para aprender com dados agrupados, a memória eletrônica pode assumir uma importância que talvez nunca tenha sido planejada. Os médicos podem se direcionar à aprendizagem

de máquina para o diagnóstico e aconselhamento sobre tratamentos, e não apenas como uma ferramenta de suporte.

Informática Aplicada à Saúde

A Informática em Saúde é uma área que surge no horizonte acadêmico de maneira esperançosa e aliciando profissionais de diversos segmentos investigando em cursos de capacitação uma formação ampla e que lhe confira capacidade de desempenho (RONDON *et al.*, 2013). Para chegarmos ao ponto central do uso e avanço da computação na área médica, devemos falar também sobre o ensino da informática para os profissionais da área da saúde, tendo em vista que é de suma importância o entendimento sobre a tecnologia proposta.

A Informática Médica é a área de conhecimento que estuda a aplicação dos recursos tecnológicos no ensino, na prática, na assistência e no gerenciamento da assistência e do cuidado. Recursos como reconhecimento de voz, bancos de conhecimento, projeto genoma e mesmo a Internet, têm oferecido para a Medicina uma gama de possibilidades para melhoria do desempenho profissional e melhoria do atendimento ao cliente/paciente (MARIN; CUNHA; 2006, p.1)

A formação e a capacitação dos profissionais da saúde têm grande impacto no uso das tecnologias voltadas para a área, exigindo que os mesmos estejam cada vez mais preparados para acompanhar a evolução tecnológica e promover a convergência entre o desenvolvimento tecnológico e a aplicação de forma humanizada e integrada aos pressupostos ético-científicos da saúde.

A tecnologia é o único meio de viabilizar o uso da informação em saúde nos tempos atuais e muito mais será para o futuro quando a medicina personalizada toma posição de destaque. Quem não reconhece hoje a importância da adoção plena dos recursos da tecnologia da informação e comunicação na saúde, não conhecerá, no futuro, o sucesso (MARIN; PERES, 2015).

A abordagem sobre o tema de informática na saúde pode ser apresentada de várias formas, tanto como área de informação e aplicabilidade, quanto como instrumentos para o desenvolvimento das pesquisas e melhorias na área. Neste sentido, diante da complicação que envolve o conhecimento da informática médica, vemos que o desenvolvedor deve buscar aprendizagem prévia, fazendo

assim uma ferramenta que irá auxiliar na resolução de diagnósticos para a melhoria e mapeamento de doenças e pacientes (MARIN *et al.*, 2005).

Atualmente observamos vários casos de softwares e algoritmos de *Machine Learning* que auxiliam em diagnósticos e exames, como o d-GDM, um software para diagnóstico de DMG (diagnóstico pré-gestacional de diabetes) que usa os critérios endossados pelo Grupo de Estudos da Associação Internacional de Diabetes e Gravidez, modificado pela Organização Mundial de Saúde. O operador requer informações sobre o período gestacional e seleciona as opções apropriadas de marcador glicêmico no software. Ao fim, o programa apresentará o diagnóstico e as informações para o acompanhamento. (VOLANSKI, *et al.*, 2019).

Complementando a informática na saúde, é importante falar sobre a IAM (Inteligência Artificial Médica). Esses sistemas de IAM surgiram para ajudar os profissionais da saúde em suas atividades rotineiras, auxiliando em tarefas como manipulação de dados e conhecimento. Clancey e Shortliffe (1984) definiram a IAM da seguinte maneira: “Inteligência Artificial Médica se preocupa primariamente com a construção de programas de IA que realizam diagnósticos e fazem recomendações terapêuticas”.

Hoje, apesar de todos os avanços, é limitada a utilização de métodos de Inteligência Artificial para o desenvolvimento de ferramentas que, de fato, ajudem na tomada de decisão dos médicos em seus julgamentos. Esse processo de decisão acontece em vários pontos da atividade médica. Algumas delas são consideradas elementares, como por exemplo a interpretação de um resultado de laboratório. Entretanto, existem três outras situações que merecem atenção médica nas quais o computador pode ajudar nas decisões. Elas estão relacionadas com a medicina clínica: Diagnóstico; Prognóstico; e Planejamento terapêutico.

Segundo Fernandes (1997), a evolução da Inteligência Artificial na saúde pode ser dividida em quatro estágios. No primeiro estágio, que ocorreu entre 1968 e 1976, apareceram os primeiros sistemas desenvolvidos para saúde, com foi o caso do CASNET desenvolvido em 1972, que usou regras de trabalho causais para descrição de processos de doenças. Também o MYCIN feito em 1974, que basicamente era um raciocínio modular baseado em regras, o

DIALOG/INTERNIST de 1975, que utilizava redes de trabalho hierárquico, e o PIP elaborado em 1976, que mostrava *templates* para definições de doenças.

Trabalhos Relacionados

Diferentes estudos buscaram realizar a análise de dados de eletrocardiograma utilizando técnicas computacionais, tal como realizado neste trabalho. A seguir são apresentados alguns destes trabalhos.

Chen *et al.* (2016), em seu trabalho realizou a classificação de dados de ECG baseado no banco de dados MIT-BIH. A metodologia foi dividida em quatro etapas: pré-processamento, segmentação dos batimentos, extração dos dados e classificação dos recursos. Na fase de pré-processamento, vários tipos de ruídos são removidos a partir dos sinais originais de entrada ECG brutos. No estágio de segmentação do batimento cardíaco, os sinais de ECG são segmentados usando os locais de batimento oferecidos. No estágio de extração do recurso, a matriz de padronização e projeção é aplicada a cada batimento cardíaco. O descritor da pulsação do coração é representado em um espaço de menor dimensão. Além disso, informações dinâmicas sobre os batimentos cardíacos são representadas por conjuntos de intervalos RR ponderados (Figura 1), em que cada intervalo é a distância entre duas ondas R sucessivas. A medição de cada intervalo é feita desde o início de uma onda R até o início da próxima onda e sua duração depende da frequência cardíaca analisada. Na etapa de classificação, um classificador SVM (*Support Vector Machines*) é usado na classificação de batimentos cardíacos finais. O método utilizou 90.808 registros, e juntamente com o algoritmo wRR (*WeightedRoundRobin*) atingiu a acurácia de 98,46%.

Figura 1 – Ilustração de intervalo RR.



Fonte: Adaptado de Figuiha (2013).

O trabalho de Rodriguez et al (2005), foi desenvolvido utilizando árvores de decisão (método j48) através do software Weka para classificar os batimentos a partir de critérios considerados relevantes. Segundo os autores, o Weka foi utilizado por ser um software de código aberto sob a licença Geral GNU, e possui uma grande aceitação entre a comunidade e aprendizagem der máquina. As classificações dos batimentos alcançaram uma precisão de 96,13% utilizando 85.263 registros.

Já o trabalho desenvolvido por Kaya e Pehlivan (2015) utilizou 200 amostras de séries temporais de batimentos cardíacos. Essas amostras foram aplicadas aos métodos de classificação como vetores de entrada. Um parâmetro foi realizado como etapa de otimização para obter o parâmetro dos valores. Foi utilizado o algoritmo NN (*Nearest neighbor*), que foi treinado como algoritmo de propagação. Na fase de treinamentos e testes, os parâmetros do ciclo e taxa de aprendizado foram definidos com 500 e 0,3 atingindo a acurácia final de 97.9%.

O estudo realizado por Prasad e Sahambi (2003) para classificação de ECG, utilizou Redes Neurais Artificiais *feedforward* com duas camadas ocultas. No trabalho, todos os neurônios utilizaram a função de ativação sigmoide. Através o algoritmo de retro propagação, a rede foi treinada com valores moderados de taxa de aprendizado e *momentum*. Os pesos são atualizados para cada vetor de treinamento e a condição de finalização é que o erro do quadrado da soma atinja um valor mínimo. A precisão média do reconhecimento foi de 96,79% utilizando-se 13 tipos diferentes de arritmias do conjunto de dados do MIT-BIH.

Material e Métodos

Os dados para classificação de batimentos cardíacos foram obtidos por meio do portal PhysioNet, nomeado como “MIT-BIH Arrhythmia Dataset” (MOODY e MARK, 2001), contendo aproximadamente 110.000 dados


objetivando realizar a classificação de batimentos cardíacos baseado em um modelo de redes neurais, obtendo informações sobre o risco de ocorrer um infarto do miocárdio em cada análise. O *dataset* utilizado contém 48 trechos de meia hora de gravações ambulatoriais de ECG de dois canais obtidos em 47 indivíduos diferentes no Laboratório de Arritmias BIH entre 1975 e 1979, na taxa de amostragem de 125Hz, e cada batida foi anotada por pelo menos dois cardiologistas. As gravações foram digitalizadas em 360 amostras por segundo por canal com resolução de 11 bits em uma faixa de 10 mV, chegando a aproximadamente 110.000 dados obtidos. Os dados são divididos em cinco classes baseados na AAMI EC57: N (normal); S (contração atrial prematura); V (contração ventricular prematura); F (fusão de ventricular e normal) e Q (inclassificável).

Para processamento dos dados utilizou-se técnicas de aprendizagem de máquina (*deep learning*) através linguagem de programação Python e de suas biblioteca scikit-learn, TensorFlow e Keras. Os parâmetros utilizados e os códigos implementados estão disponíveis em <http://bit.ly/2YxtijE> e <http://bit.ly/2SUjJCo>. A metodologia de desenvolvimento do estudo baseou-se no trabalho de Kachuee, Fazeli e Sarrafzadeh (2018).

Resultados e Discussões

Baseado no trabalho de Kachuee, Fazeli e Sarrafzadeh (2018), implementou-se o primeiro experimento com o modelo de rede neural convolucional, em que as batidas extraídas foram usadas como entradas, passando pelas camadas de convolução e de pooling. A rede de previsão consistiu em cinco blocos residuais seguidos por duas camadas totalmente conectadas com 32 neurônios cada e uma camada softmax para prever as probabilidades da classe de saída. Cada bloco residual contém duas camadas de convoluções, duas ReLU, uma conexão de salto residual e uma camada de pooling. No total, a rede resultante é uma rede profunda composta por 13 camadas de peso. O modelo de rede neural utilizada está sendo representada pela figura 2.


Figura 2 – Modelo de arquitetura da rede neural convolucional utilizada no primeiro experimento.



Fonte: Adaptado de Kachuee, Fazeli e Sarrafzadeh (2018).

Seguimos a metodologia utilizada pelos autores, no experimento realizado não atingiu-se a acurácia descrita, que foi de 0,96, porém atingimos apenas 0,76. A matriz de confusão do experimento realizado neste trabalho é apresentada na figura 3. Os parâmetros e códigos utilizados para esse experimento estão disponíveis em <http://bit.ly/2YxtjJE>.


Figura 3 – Matriz de confusão sem normalização.



Fonte: Autoria própria, adaptado de Kachuee, Fazeli e Sarrafzadeh (2018).

Após o primeiro experimento não ter atingido uma acurácia satisfatória, foi implementado um novo modelo baseado em uma *Perceptron* Multicamadas (MLP - *Multi Layer Perceptron*). A MLP utilizada no desenvolvimento contém 4 camadas ocultas, sendo a primeira camada com 187 neurônios, o que corresponde a quantidade de atributos do *dataset*, a segunda com 374, a terceira com 94 e a quarta com 42. A função de ativação para cada camada é a ReLU, em que ela é amplamente utilizada em redes neurais. Ela é não linear, e pode ter várias camadas de neurônios ativadas por ela (Figura 4).

Figura 4 – Modelo de arquitetura da rede neural MLP utilizada.




Fonte: Autoria Própria (2021).

O treinamento foi realizado em 200 épocas, que é cada iteração que o modelo realiza para aprimorar seus parâmetros. Em sua totalidade, foram separados 25% dos dados para teste e 75% para treinamento da rede. Os parâmetros e códigos utilizados neste experimento estão disponíveis em <http://bit.ly/2SUjJCo>.

A Figura 5 apresenta a matriz de confusão resultante da classificação. Os números nos blocos são as amostras classificadas em cada categoria, normalizadas com os valores entre 0 e 1, arredondadas para 2 dígitos. Assim, o modelo é capaz de fazer previsões precisas e distinguir as classes para cada análise.

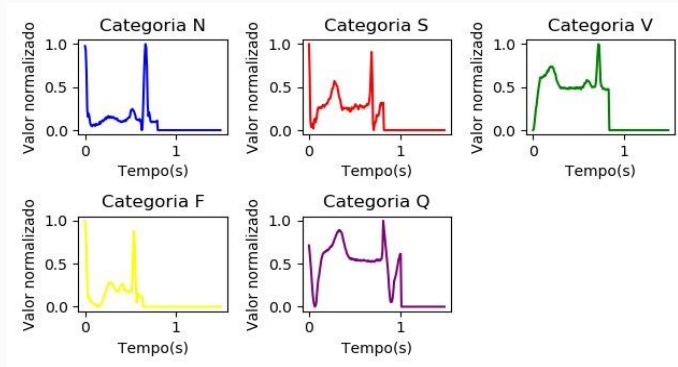
Figura 5 – Matriz de confusão sem normalização.



Fonte: Autoria própria, adaptado de Kachuee, Fazeli e Sarrafzadeh (2018).

Na figura 5A, observa-se um exemplar de cada batimento cardíaco usado para a identificação e separação das classes no treinamento da rede neural. As classificações finais dos 109.446 registros ficaram dispostas conforme a figura 5B, atingindo a acurácia de 0,98. Sendo assim, obtendo um resultado ainda melhor do que os autores. O treinamento da rede levou 2 horas e 34 minutos em um computador com 12GB de RAM, CPU com 4 núcleos de 3.9Ghz.

Figura 5A – Exemplar de batimentos cardíacos



Fonte: Autoria própria (2021).

Figura 5B – Classificação dos dados.

Categoria	Quantidade de dados incluídos
N	90.589
S	8.039
V	7.236
F	2.779
Q	803

Fonte: autoria própria (2021).

Conclusões

A utilização das técnicas de aprendizagem de máquina aplicada à saúde é uma realidade, conseguindo analisar grandes quantidades de dados,

chegando a resultados satisfatórios. Neste trabalho, buscou-se estudar e implementar modelos computacionais através de técnicas de *deep learning* para análise de dados de ECG e classificação da arritmia, em dois modelos distintos, obtendo em um deles uma ótima acuraria (98%), mostrando que a representação obtida neste trabalho pode ser utilizada como base para treinar classificadores precisos, comparável com métodos do estado da arte da literatura.

As técnicas utilizadas são capazes de realizar previsões nas tarefas propostas com acurácia satisfatória. Ademais, as tecnologias e técnicas implementadas, podem ser aplicadas para outras soluções. No que tange a pesquisa acerca da classificação automática de batimentos cardíacos, observou-se uma grande convergência na literatura para uma mesma fonte de dados (PhysioNet - “MIT-BIH Arrhythmia Dataset”), o que sugere a necessidade da geração e disponibilização de novos *datasets*, estimulando assim a pesquisa nesta importante área.

Referências

ANDERSON, Susan Leigh; ANDERSON, Michael. Machine Ethics: Creating an Ethical Intelligent Agent. AAAI - Association for the Advancement of Artificial Intelligence, [S. l.], p. 15-25, 10 dez. 2007.

CHEN, Shanshan *et al.* Heartbeat classification using projected and dynamic features of ECG signal. Biomedical Signal Processing and Control, [S.l.], p. 1-9, 22 jul. 2016.

FERNANDES, A. P. S. Sistema Especialista Difuso de Apoio ao Aprendizado do Traumatismo Dento-Aveolar Utilizando Recursos Multimídia. Dissertação. Florianópolis: Universidade Federal de Santa Catarina, 1997.

FIGUINHA, Fernando. Como calcular a frequência cardíaca pelo eletrocardiograma (ECG). [S. l.], 2013. Disponível em: <https://cardiopapers.com.br/curso-basico-de-eletrocardiograma-parte-07-frequencia-cardiaca/>.

G. B. Moody and R. G. Mark, “The impact of the mit-bih arrhythmia database,” IEEE Engineering in Medicine and Biology Magazine, vol. 20, no. 3, pp. 45–50, 2001

J. RIGBY, Michael. Ethical Dimensions of Using Artificial Intelligence in Health Care. AMA Journal of Ethics, [S. l.], p. 1, 1 fev. 2019.

KACHUEE, Mohammad; FAZELI, Shayan; SARRAFZADEH, Majid. Ecg heartbeat classification: A deep transferable representation. In: 2018 IEEE International Conference on Healthcare Informatics (ICHI). IEEE, p. 443-444, 2018.

KAYA, Yasin; PEHLIVAN, Hüseyin. Classification of Premature Ventricular Contraction in ECG. International Journal of Advanced Computer Science and Applications, [S.l.], ano 7, v. 6, p. 1-7, 7 nov. 2015

KONONENKO, Igor. Machine learning for medical diagnosis: history, state of the art and perspective. Science Direct, [S. l.], p. 89-109, 2 ago. 2001.

L. GOLDBERGER, Ary et al. PhysioBank, PhysioToolkit, and PhysioNet. AHA Journals, [S. l.], p. 1, 13 jun. 2000.

MARIN, Heimar de Fatima; PERES, Heloisa H. Ciqueto. O Ensino de Informática em Saúde e o Currículo de Enfermagem. Journal of Health Informatics, [S. l.], p. 1-2, 9 dez. 2015.

MARIN, H. F; CUNHA, I. C. K. O. Perspectivas atuais da Informática em Enfermagem. Rev. bras. enferm. [online], vol.59, n.3, pp. 354-357. ISSN 0034-7167, 2006.

PRASAD, G. Krishna; SAHAMBI, J. S. Classification of ECG Arrhythmias using Multi-Resolution Analysis and Neural Networks. Conference on Convergent Technologies for Asia-Pacific Region, Guwahati, Assam, 13 mar. 2003.

RODRÍGUEZ, Jimena; GOÑI, Alfredo; ILLARRAMENDI, Arantza. Real-Time Classification of ECGs on a PDA. IEEE Transactions on Information Technology in Biomedicine, [S.l.], ed. 1, p. 1-12, 2 mar. 2005.

RONDON, E; NOVAIS, M; NAPPO, S. A importância da informática em saúde na educação superior nos cursos da área da saúde. Gestão e Saúde, [S.l.], 1, mar. 2013.

S. CHAR, Danton; H. SHAH, Nigam; MAGNUS, David. Implementing Machine Learning in Health Care — Addressing Ethical Challenges. The New England Journal of Medicine, [S. l.], p. 1, 15 mar. 2018.

SANTOS, Marcel Koenigkam *et al.* Inteligência artificial, aprendizado de máquina, diagnóstico auxiliado por computador e radiômica: avanços da imagem rumo à medicina de precisão. Radiologia Brasileira, [s. l.], 15 abr. 2019.

SHORTLIFFE, Edward H.; CLANCEY, William J. Readings in Medical Artificial Intelligence: The First Decade. First. ed. [S.l.]: Addison Wesley, 1984. 512 p. v. 1. ISBN 9780201108545.

VOLANSKI, Waldemar *et al.* D-GDM: A mobile diagnostic decision support system for gestational diabetes. Archives of Endocrinology and Metabolism, [S. l.], p. 1-3, 2 set. 2019.

Z., Obermayer; E.J., Emanuel. Predicting the Future - Big Data, Machine Learning, and Clinical Medicine. US National Library of Medicine, [S. l.], p. 1-8, 29 set. 2016.

