

Proposta de sistema web de apoio a decisão clínica baseado em aprendizado de máquina para análise de sobrevivência de pacientes com doenças cardiovasculares

Francisco Adrian Vinicius Chaves Sampaio
Metrópole Digital/IMD
Universidade Federal do Rio Grande do Norte/UFRN
Pau dos Ferros, RN.
adrianvinicius.cs@gmail.com

Resumo – A inteligência artificial utilizada para o apoio de decisões clínicas tem tido uma popularidade crescente no cenário mundial da saúde, possibilitando os profissionais desta área efetuarem diagnósticos e tratamentos mais eficientes com o auxílio dessa tecnologia. Diante disso, este trabalho apresenta uma proposta de um Sistema de Apoio a Decisão Clínica (SADC), que utiliza métodos de aprendizado de máquina para gerar previsões de chance de sobrevivência de pacientes acometidos por doenças cardiovasculares. Os resultados mostram que há um grande potencial na utilização de métodos de aprendizado de máquina em SADC's, devido a robustez na precisão das previsões, a possibilidade de um atendimento mais individualizado ao paciente, e a simplicidade na utilização destes sistemas inteligentes.

Palavras-chave — inteligência artificial, medicina computacional, saúde cardiovascular, machine learning

I. INTRODUÇÃO

Doenças cardiovasculares são a principal causa de morte no mundo, com cerca de 17,9 milhões de mortes por ano, representando 31% das mortes globais. [1] Das doenças cardiovasculares, a insuficiência cardíaca se destaca por sua alta morbidade e mortalidade. [2] Insuficiência cardíaca é definida como a incapacidade do coração de suprir o sistema periférico com a quantidade necessária de sangue e oxigênio. A severidade desse quadro é categorizada de acordo com a classificação funcional da New York Heart Association (NYHA), que se baseia em sintomas clínicos e níveis de atividade física do paciente [3].

As práticas clínicas modernas geram uma grande quantidade de registros eletrônicos de saúde, o que permite que estudos sejam feitos a partir destes dados para avaliar fatores de risco, prever resultados de tratamentos e efetuar diagnósticos com maior confiabilidade e eficiência. Neste contexto, a inteligência artificial tem ganhado tração como uma forma de adquirir novas percepções em relação a essas doenças através da análise de dados e previsão de resultados na cardiologia e em outras áreas médicas [4].

Esse estudo tem como propósito desenvolver e validar um modelo de aprendizado de máquina capaz de prever a chance de sobrevivência de um paciente acometido por insuficiência cardíaca, baseada em uma série de dados clínicos, e integrá-lo com um sistema web como um protótipo de sistema de apoio a decisão clínica.

II. REVISÃO DE LITERATURA

Sistemas de apoio a decisão tem como objetivo auxiliar no processo de tomadas de decisão. Na medicina, eles são denominados Sistemas de Apoio a Decisão Clínica (SADC). [5]. Estes sistemas tradicionalmente focam em ajudar clínicos a aplicar conhecimento médico derivado do conhecimento tradicional para cuidar de pacientes.

A partir disso, [6] propõe 3 componentes principais para o desenvolvimento de SADC's inteligentes: Descobrimiento de conhecimento, curadoria, e aplicação de conhecimento. Com os avanços do aprendizado de máquina aplicado a medicina, o desenvolvimento de SADC's inteligentes utilizando inteligência artificial foi viabilizado.

O aprendizado de máquina pode ser utilizado tanto para a etapa de descobrimiento de conhecimento, através da análise de registros eletrônicos de saúde, passando por uma curadoria que pode ser feita por profissionais da saúde, com o objetivo de definir detalhes de como o SADC funcionaria para uma melhor implementação clínica, até a aplicação, onde um modelo de inteligência artificial adaptado e treinado poderia ser utilizado clinicamente para apoiar as decisões médicas.

Há um esforço grande por parte de pesquisadores para desenvolver SADC's para auxiliar decisões clínicas, no entanto, ainda há pouca informação quanto a eficácia real destes para a melhora dos diagnósticos e tratamentos médicos [7]. Na área de aprendizado de máquina aplicado a saúde cardiovascular, já existem diversos estudos relatando uma precisão maior do que métodos estatísticos tradicionais na previsão de resultados [8] [9] [10].

Estes modelos de aprendizado de máquina apresentam novas ferramentas para utilizar a grande quantidade de dados gerados na área da saúde a favor da eficiência das decisões clínicas, podendo gerar um grande impacto na análise de risco e de potenciais resultados. Entretanto, a natureza de “caixa preta” dos algoritmos de aprendizado de máquina pode trazer problemas, mesmo com uma alta capacidade de prever resultados de interesse, a falta de uma lógica familiar por trás do “output” da máquina pode trazer receio ao profissional clínico na hora de interpretá-lo quando se tratam de decisões que podem mudar vidas [11].

III. MÉTODOS

A. Dataset

O dataset utilizado nesse estudo foi disponibilizado online, contendo dados coletados por autores paquistaneses de um estudo no Instituto de Cardiologia de Faisalabad e no Allied Hospital de Faisalabad, no Paquistão [12]. Todos os pacientes haviam disfunção sistólica no ventrículo esquerdo e haviam sofrido insuficiência cardíaca que os colocavam nas classes III ou IV da classificação NYHA de insuficiência cardíaca. O dataset contém 13 variáveis, com as características demonstradas na Tabela 1.

Tabela 1. Descrição, unidades e intervalo das variáveis

Variável	Descrição	Unidade	Intervalo
Age	Idade do paciente	Anos	[40, ..., 95]
Anaemia	Se o paciente possui anemia	Boolean	0, 1
High blood pressure	Se o paciente possui hipertensão	Boolean	0, 1
Creatine Phosphokinase (CPK)	Nível da enzima CPK no sangue	mcg/L	[23, ..., 7861]
Diabetes	Se o paciente possui diabetes	Boolean	0, 1
Ejection fraction	Porcentagem de sangue deixando o coração a cada contração	Porcentagem	[14, ..., 80]
Sexo	Sexo do paciente	Binário	0, 1
Platelets	Nível das plaquetas no sangue	kiloplatelets/mL	[25,01, ..., 850,00]
Serum creatinine	Nível de creatina no sangue	mg/dL	[0,50, ..., 9,40]
Serum sodium	Nível de sódio no sangue	mEq/L	[114, ..., 148]
Smoking	Se o paciente fuma	Boolean	0, 1
Time	Período de acompanhamento	Dias	[4, ..., 285]
Death Event	Se o paciente morreu durante o período de acompanhamento	Boolean	0, 1

B. Ranking de variáveis

Para analisar quais seriam as variáveis utilizadas no modelo final, foram empregados dois métodos de ranking de variáveis: Score de importância com Random Forest Classifier (RFC) e ANOVA Score. Com os resultados demonstrados a seguir:

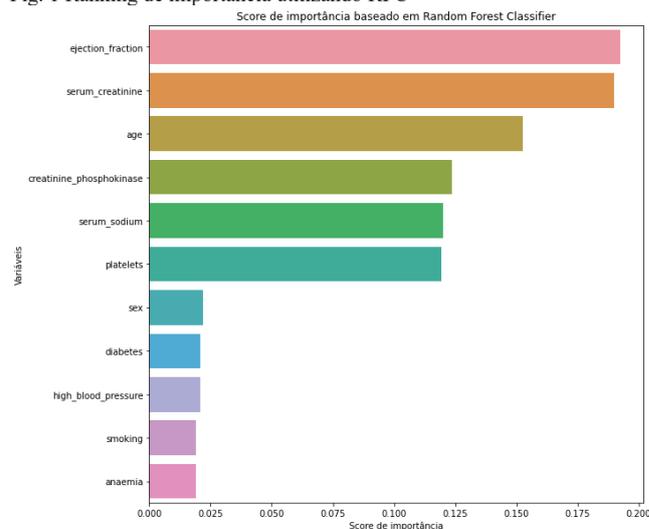
Na Tabela 2, observa-se que a creatinina sérica e a fração de ejeção tiveram os melhores coeficientes, corroborando com o resultado obtido através do Score de importância com RFC, demonstrado na Fig. 1.

O destaque da creatinina sérica e fração de ejeção corrobora com outro estudo realizado com o mesmo dataset [9].

Tabela 2. Ranking com ANOVA Score e Valor P.

Variável	ANOVA Score	Valor P
Serum Creatinine	23,0	0,000002
Ejection Fraction	18,0	0,000040
Age	11,0	0,002044
Serum Sodium	4,0	0,049437
High blood pressure	4,0	0,049437

Fig. 1 Ranking de importância utilizando RFC



Score de importância gerado pelo algoritmo de ranking de variáveis utilizando Random Forest Classifier.

A partir desses resultados, formamos três datasets para realizar o treinamento e a validação dos algoritmos de aprendizado de máquina:

- Dataset com as 12 variáveis originais.
- Dataset com as 5 variáveis que melhor performaram em ambos os testes (ejection fraction, sérum creatinine, age, creatine phosphokinase, sérum sodium, platelets, high blood pressure)
- Dataset com as 2 variáveis que melhor performaram nos dois testes (ejection fraction e serum creatinine)

Cada um dos datasets supracitados foi separado entre dataset de treinamento e dataset de teste.

C. Seleção dos algoritmos de aprendizado de máquina

Para efetuar a seleção, foram escolhidos 4 algoritmos de aprendizado de máquina para classificação: Random Forest Classifier (RFC), Extreme Gradient Boost (XGBoost), Linear Discriminant Analysis (LDA) e K-Nearest Neighbors (KNN).

Cada modelo foi treinado e testado em cada um dos datasets citados anteriormente. Para a validação, foram utilizados 5 métodos: Matthew Correlation Coefficient (MCC), F1 Score, ROC AUC, Average Precision Score (APS) e matriz de confusão para obter os positivos verdadeiros (TP) e os falsos verdadeiros (TN).

Os resultados obtidos nos testes com diferentes combinações de variáveis e algoritmos são demonstrados na Tabela 3, Tabela 4 e Tabela 5.

Tabela 3. Dataset com todas as variáveis

Algoritmo	MC	F1	ROC	APS	TP	TN
RFC	0,554	0,694	0,763	0,620	43	17
XGBoost	0,609*	0,715*	0,800*	0,664*	43	19*
LDA	0,489	0,622	0,718	0,577	44	14
KNN	0,046	0,176	0,514	0,634	44*	3

^a Valores em negrito e com * indicam melhor performance em cada teste

Tabela 4. Dataset com as 5 variáveis de melhor performance

Algoritmo	MCC	F1	ROC	APS	TP	TN
RFC	0,557	0,706	0,771	0,620	42	18*
XGBoost	0,586*	0,720*	0,781*	0,642*	43	18*
LDA	0,489	0,622	0,718	0,577	44	14
KNN	0,086	0,182	0,524	0,368	45*	3

^b Valores em negrito e com * indicam melhor performance em cada teste

Tabela 5. Dataset com ejection fraction e serum creatinine

Algoritmo	MCC	F1	ROC	APS	TP	TN
RFC	0,616*	0,723*	0,784*	0,669*	45	17*
XGBoost	0,522	0,667	0,744	0,598	43	16
LDA	0,321	0,389	0,609	0,577	46	7
KNN	0,567	0,634	0,730	0,634	47*	13

^c Valores em negrito e com * indicam melhor performance em cada teste

Os resultados corroboram com resultados obtidos em outro estudo utilizando o mesmo dataset [9]. A combinação da utilização de creatinina sérica e fração de ejeção como variáveis, e o algoritmo de Random Forest Classifier gerou o melhor resultado, como observado na Tabela 5. Portanto, foi o modelo escolhido para ser utilizado no SADC.

D. Desenvolvimento do Aplicativo Web

Para o desenvolvimento da plataforma web, foi utilizado a linguagem Python, com o framework Django para o back-end, e HTML e CSS para o desenvolvimento front-end. A integração com o modelo de aprendizado de máquina foi feita através da biblioteca joblib.

O funcionamento do sistema é demonstrado nas figuras a seguir:



Fig.1 Página inicial do sistema

Nessa tela, o usuário insere os dados do paciente, nas unidades indicadas pelo sistema.

Após enviar os dados para o modelo de aprendizado de máquina realizar a predição, o SADC gera o resultado da predição.



Fig. 2 Página gerada ao inserir dados que o sistema prediz como alta chance de sobrevivência.



Fig.3 Página gerada ao inserir dados que o sistema prediz como alta chance de mortalidade

IV. CONCLUSÕES

A utilização de SADC's inteligentes com aprendizado de máquina tem grande potencial de impactar os tratamentos e diagnósticos clínicos. Através deste protótipo, foi demonstrada a capacidade dos modelos de inteligência artificial de gerar resultados satisfatórios em predição de sobrevivência de pacientes com problemas cardiovasculares, mas existem muitos outros tópicos que se beneficiariam de sistemas inteligentes de apoio a decisão clínica. A proposta apresentada ainda está longe de ser um sistema pronto para o emprego clínico, mas demonstra o grande potencial desses sistemas de gerarem predições com alta precisão, com uma grande usabilidade e simplicidade em seu uso. Como limitações do estudo, podemos citar a pouca quantidade de dados (apenas 299 pacientes) e a quase nula variação geográfica dos pacientes (todos são da mesma região do Paquistão).

Para trabalhos futuros, a obtenção de datasets com dados de pacientes de diferentes regiões geográficas, contendo as mesmas variáveis observadas nos dados desse estudo possibilitaria a validação do modelo de aprendizado de máquina, analisando a precisão do modelo treinado neste estudo em dados de diferentes regiões geográficas, e também o treinamento de novos modelos utilizando maior quantidade de dados e com maior variação geográfica. Desta forma, trabalhos posteriores necessitariam de um esforço de pesquisa para buscar estudos feitos em diferentes regiões geográficas que seguissem o mesmo método de coleta de dados que gerou o dataset utilizado neste artigo [12].

V. REFERÊNCIAS

- [1] Q. Mattingly, “https://www.who.int/health-topics/cardiovascular-diseases#tab=tab_1,” Organização Mundial da Saúde. [Online].
- [2] P. Ponikowski, A. A. Voors, S. D. Anker, H. Bueno, J. G. F. Cleland, J. S. A. Coats, V. Falk, J. R. González-Juanatey, V.-P. Harjola, E. A. Jankowska, M. Jessup, C. Linde, P. Nihoyannopoulos, J. T. Parissis, B. Pieske, J. P. Riley, M. C. G. Rosano, L. M. Ruilope, F. Ruschitzka, F. H. Rutten e P. van der Meer, “2016 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure: The Task Force for the diagnosis and treatment of acute and chronic heart failure of the European Society of Cardiology (ESC) Developed with the special contribution of,” *Eur Heart J.*, 2016.
- [3] E. Tanai e S. Frantz, “Pathophysiology of Heart Failure,” *In Comprehensive Physiology, R. Terjung*, 2015.
- [4] K. Shameer, K. W. Johnson, B. S. Glicksberg, J. T. Dudley e P. P. Sengupta, “Machine learning in cardiovascular medicine: are we there yet?,” *Heart.*, 2018.
- [5] J. Bortolin e S. A. Martini, “Sistemas de Apoio à Decisão,” 2005.
- [6] D. E. Kurant, A. S. Dighe e J. M. Baron, “Machine Learning and Other Decision Support Tools.,” *Clinics in laboratory medicine*, 2019.
- [7] A. Awaysheh, J. Wilcke, F. Elvinger, L. Rees, W. Fan e K. L. Zimmerman, “Review of Medical Decision Support and Machine-Learning Methods.,” *Vet Pathol.*, 2019.
- [8] M. Z. Alam, M. S. Rahman e M. S. Rahman, “A Random Forest based predictor for medical data classification using feature ranking.,” *Informatics in Medicine Unlocked, Volume 15*, 2019.
- [9] D. Chicco e G. Jurman, “Machine learning can predict survival of patients with heart failure from serum creatinine and ejection fraction alone.,” *BMC Med Inform Decis Mak*, 2020.
- [10] S. F. Weng, J. Reys, J. Kai, J. M. Garibaldi e N. Qureshi, “Can machine-learning improve cardiovascular risk prediction using routine clinical data?,” *PLoS One*, 2017.
- [11] S. J. Al'Aref, K. Anchouche, G. Singh, P. J. Slomka, K. K. Kolli, A. Kumar, M. Pandey, G. Maliakal, A. R. van Rosendaal, A. N. Beecy, D. S. Berman, J. Leipsic, K. Nieman, D. Andreini, G. Pontone, J. U. Schoepf, L. J. Shaw, H.-J. Chang, J. Narula, J. J. Bax, Y. Guan e J. K. Min, “Clinical applications of machine learning in cardiovascular disease and its relevance to cardiac imaging.,” *Eur Heart J.*, 2019.
- [12] T. Ahmad, A. Munir, M. Aftab, S. H. Bhatti, M. Aftab e M. A. Raza, “Survival Analysis of heart failure patients: A case study.,” *PLoS One*, 2017.