

Tópicos nas ciências da Saúde

Volume IX

Aris Verdecia Peña

organizadora



Pantanal Editora

2022



Aris Verdecia Peña
Organizadora

Tópicos nas ciências da Saúde
Volume IX



Pantanal Editora

2022

Copyright© Pantanal Editora

Editor Chefe: Prof. Dr. Alan Mario Zuffo

Editores Executivos: Prof. Dr. Jorge González Aguilera e Prof. Dr. Bruno Rodrigues de Oliveira

Diagramação: A editora. **Diagramação e Arte:** A editora. **Imagens de capa e contracapa:** Canva.com. **Revisão:** O(s) autor(es), organizador(es) e a editora.

Conselho Editorial

Grau acadêmico e Nome

Prof. Dr. Adaylson Wagner Sousa de Vasconcelos
Profa. Msc. Adriana Flávia Neu
Profa. Dra. Allys Ferrer Dubois
Prof. Dr. Antonio Gasparetto Júnior
Profa. Msc. Aris Verdecia Peña
Profa. Arisleidis Chapman Verdecia
Prof. Dr. Arinaldo Pereira da Silva
Prof. Dr. Bruno Gomes de Araújo
Prof. Dr. Caio Cesar Enside de Abreu
Prof. Dr. Carlos Nick
Prof. Dr. Claudio Silveira Maia
Prof. Dr. Cleberton Correia Santos
Prof. Dr. Cristiano Pereira da Silva
Profa. Ma. Dayse Rodrigues dos Santos
Prof. Msc. David Chacon Alvarez
Prof. Dr. Denis Silva Nogueira
Profa. Dra. Denise Silva Nogueira
Profa. Dra. Dennyura Oliveira Galvão
Prof. Dr. Elias Rocha Gonçalves
Prof. Me. Ernane Rosa Martins
Prof. Dr. Fábio Steiner
Prof. Dr. Fabiano dos Santos Souza
Prof. Dr. Gabriel Andres Tafur Gomez
Prof. Dr. Hebert Hernán Soto Gonzáles
Prof. Dr. Hudson do Vale de Oliveira
Prof. Msc. Javier Revilla Armesto
Prof. Msc. João Camilo Sevilla
Prof. Dr. José Luis Soto Gonzales
Prof. Dr. Julio Cezar Uzinski
Prof. Msc. Lucas R. Oliveira
Profa. Dra. Keyla Christina Almeida Portela
Prof. Dr. Leandro Argentel-Martínez
Profa. Msc. Lidiene Jaqueline de Souza Costa Marchesan
Prof. Dr. Marco Aurélio Kistemann
Prof. Msc. Marcos Pisarski Júnior
Prof. Dr. Marcos Pereira dos Santos
Prof. Dr. Mario Rodrigo Esparza Mantilla
Profa. Msc. Mary Jose Almeida Pereira
Profa. Msc. Núbia Flávia Oliveira Mendes
Profa. Msc. Nila Luciana Vilhena Madureira
Profa. Dra. Patrícia Maurer
Profa. Msc. Queila Pahim da Silva
Prof. Dr. Rafael Chapman Auty
Prof. Dr. Rafael Felipe Ratke
Prof. Dr. Raphael Reis da Silva
Prof. Dr. Renato Jaqueto Goes
Prof. Dr. Ricardo Alves de Araújo (*In Memoriam*)
Profa. Dra. Sylvana Karla da Silva de Lemos Santos
Msc. Tayronne de Almeida Rodrigues
Prof. Dr. Wéverson Lima Fonseca
Prof. Msc. Wesclen Vilar Nogueira
Profa. Dra. Yilan Fung Boix
Prof. Dr. Willian Douglas Guilherme

Instituição

OAB/PB
Mun. Faxinal Soturno e Tupanciretã
UO (Cuba)
IF SUDESTE MG
Facultad de Medicina (Cuba)
ISCM (Cuba)
UFESSPA
UEA
UNEMAT
UFV
AJES
UFGD
UEMS
IFPA
UNICENTRO
IFMT
UFMG
URCA
ISEPAM-FAETEC
IFG
UEMS
UFF
(Colômbia)
UNAM (Peru)
IFRR
UCG (México)
Mun. Rio de Janeiro
UNMSM (Peru)
UFMT
Mun. de Chap. do Sul
IFPR
Tec-NM (México)
Consultório em Santa Maria
UFJF
UEG
FAQ
UNAM (Peru)
SEDUC/PA
IFB
IFPA
UNIPAMPA
IFB
UO (Cuba)
UFMS
UFPI
UFG
UEMA
IFB

UFPI
FURG
UO (Cuba)
UFT

Conselho Técnico Científico
- Esp. Joacir Mário Zuffo Júnior
- Esp. Maurício Amormino Júnior
- Lda. Rosalina Eufrausino Lustosa Zuffo

Ficha Catalográfica

**Dados Internacionais de Catalogação na Publicação (CIP)
(eDOC BRASIL, Belo Horizonte/MG)**

T674 Tópicos nas ciências da saúde [livro eletrônico]: volume IX / Organizadora
Aris Verdecia Peña. – Nova Xavantina, MT: Pantanal, 2022.
163p. : il.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

ISBN 978-65-81460-48-8

DOI <https://doi.org/10.46420/9786581460488>

1. Ciências da saúde – Pesquisa – Brasil. I. Peña, Aris Verdecia.

CDD 610

Elaborado por Maurício Amormino Júnior – CRB6/2422



Nossos e-books são de acesso público e gratuito e seu download e compartilhamento são permitidos, mas solicitamos que sejam dados os devidos créditos à Pantanal Editora e também aos organizadores e autores. Entretanto, não é permitida a utilização dos e-books para fins comerciais, exceto com autorização expressa dos autores com a concordância da Pantanal Editora.

Pantanal Editora

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000.
Nova Xavantina – Mato Grosso – Brasil.
Telefone (66) 99682-4165 (Whatsapp).
<https://www.editorapantanal.com.br>
contato@editorapantanal.com.br

Apresentação

No novo volume da Pantanal Editora sobre temas de saúde, serão mostrados vários capítulos dedicados à patologia da pneumonia cuja descoberta ocorreu em 1892, que antes era tratada como uma influência, mas aos poucos os cientistas da Sociedade perceberam que não era uma simples influência, mas uma patologia que afetou diretamente os pulmões, para o qual o tratamento teve que ser mais intensivo e medidas preventivas tiveram que ser tomadas para evitar o contágio, pois eram transmitidas por via inadvertida: como copos e colheres. Além disso, vamos ver o indivíduo como um ser social onde o uso de drogas afeta tristemente sua interação com a sociedade, não só os danos causados pelo consumo da droga.

Os capítulos abordam também o tratamento não farmacológico para o dor, procurando soluções alternativas para aqueles lugares onde não temos medicamentos ou onde a medicina não é tão avançada, especialmente em países do terceiro mundo. Agradecemos o surgimento de um capítulo onde se baseia em um modelo de inteligência artificial para ajudar aos médicos nas altas hospitalares. Muitas vezes os pacientes recebem alta e não estão 100% curados, situação difícil para o médico, pois internações prolongadas também podem ser causa de possíveis infecções. Faremos aqui o estudo de pacientes que vivem com a patologia do HIV que acomete milhares de pessoas no mundo e que graças aos retrovirais conseguiram prolongar sua vida, no entanto o uso de retrovirais também pode causar danos ao corpo que muitas vezes são irreversíveis agradecemos a colaboração de todos. Esperamos que este novo volume seja proveitoso a todos.

A organizadora


Sumário


Apresentação	4
Capítulo 1	6
Eritroblastose fetal, assistência de qualidade e as razões para um desfecho positivo	6
Capítulo 2	13
O preceptor da graduação em saúde nos	13
Capítulo 3	25
Desigualdades de sexo, raça e região na contaminação, sintomas e hospitalização por Covid-19 no Brasil	25
Capítulo 4	39
Impacto social e econômico de mulheres em situação de gravidez precoce: uma revisão integrativa de literatura	39
Capítulo 5	49
Reflexões sobre a saúde do idoso no SUS	49
Capítulo 6	53
Evidências científicas da Enfermagem sobre Letramento em Saúde de Pessoas Vivendo com HIV	53
Capítulo 7	69
Pneumonias por bactérias típicas	69
Capítulo 8	82
Pneumonias por bactérias atípicas	82
Capítulo 9	96
Pneumonia aspirativa por refluxo: uma revisão de literatura	96
Capítulo 10	108
Pneumonia por H1N1	108
Capítulo 11	116
Pneumonias Fúngicas	116
Capítulo 12	131
Um modelo de Inteligência Artificial para auxílio na decisão de alta hospitalar	131
Capítulo 13	142
Drogas e Sociedade	142
Capítulo 14	149
Espécies vegetais como estratégia não farmacológica na dor: realidade ou expectativa?	149
Índice Remissivo	162
Sobre a organizadora	163

Um modelo de Inteligência Artificial para auxílio na decisão de alta hospitalar

Recebido em: 10/06/2022

Aceito em: 00/00/0000

 10.46420/9786581460488cap13

Bruno Rodrigues de Oliveira^{1*} 

INTRODUÇÃO

A decisão sobre a alta hospitalar depende do estado de saúde do paciente e também de questões relacionadas à: quantidade de leitos disponíveis; riscos associados à hospitalização como infecções, depressão, trombose, condicionamento físico; custos gerais de internação; plano de saúde, dentre outros (Anderson et al., 1988; Cesar; Santos, 2005; Silva et al., 2014).

Foi estimado que os dias extras de internação podem representar entre 11% a 30% dos custos hospitalares totais por paciente, e que estes atrasos afetam mais de 22% dos pacientes (Landeiro et al., 2016), ocasionando muitas vezes o cancelamento de cirurgias, atrasos em tratamentos de outros pacientes e repercussões em cascata para diversos outros procedimentos médicos (Rojas-García et al., 2017).

Um instrumento largamente utilizado no mundo todo para determinação da alta hospitalar é denominado de *Appropriateness Evaluation Protocol* (AEP) (McDonagh et al., 2000; Vetter, 2003; Silva et al., 2014). O AEP foi proposto como um instrumento independente de diagnóstico e para a medicina adulta. Os critérios do AEP que determinam um tratamento hospitalar são categorizados em três categorias: (a) serviços médicos, (b) serviços de enfermagem/suporte de vida e (c) fatores de condição do paciente. Quando qualquer um destes critérios é atendimento, o tratamento hospitalar é recomendado (Gertman; Restuccia, 1981). Essas categorias englobam 27 critérios objetivos. Este instrumento foi utilizado para analisar 395 prontuários em dois hospitais públicos de ensino no estado de Minas Gerais. Os autores constataram um atraso na alta hospitalar superior a 58%. Tendo um atraso médio por paciente superior a 4 dias (Silva et al., 2014).

Os métodos de Inteligência Artificial (*Artificial Intelligence* - AI) e Aprendizado de Máquina (*Machine Learning* – ML) têm ampla gama de aplicações para resolução de problemas nas mais variadas áreas da medicina. Seu uso tem crescido nos últimos anos, principalmente devido ao aumento significativo na quantidade de dados disponíveis bem como à evolução dos softwares e hardwares necessários para

¹ Pantanal Editora

* Autor(a) correspondente: bruno@editorapantanal.com.br

processamento (de Abreu et al., 2017; Gossler et al., 2016; de Oliveira et al., 2019; Chen et al., 2021; Li et al., 2021; Kiener, 2021; Bhinder et al., 2021).

Neste trabalho propõe-se a obtenção de um modelo de AI (ML) que seja capaz de auxiliar na decisão sobre a alta hospitalar, alisando tão somente os resultados de exames laboratoriais (hemograma). Para tanto, o modelo é construído utilizando dados de mais de 4 mil pacientes de um hospital privado na Indonésia. Esta base de dados foi elaborada por Mujiono (2020) e consiste de 10 variáveis mais a decisão tomada a respeito da alta hospitalar. Também é investigado se os modelos aprendidos diferenciam entre gênero masculino ou feminino, pois os valores de referência do hemograma são diferentes dependendo do gênero (Rosenfeld et al., 2019). Além de analisadas quais são as variáveis mais importantes na determinação da alta hospitalar.

A obtenção de modelos dessa natureza é de grande valia, pois podem auxiliar os médicos e suas equipes, gestores de hospitais e planos de saúde a selecionarem no tempo adequado àqueles pacientes que estão aptos à alta hospitalar, evitando todos os transtornos e custos acima mencionados.

MATERIAIS E MÉTODOS

Os dados utilizados nesta pesquisa foram obtidos em um hospital particular em Jakarta, Indonésia, por Mujiono (2020). Foram coletados dados de 80 mil pacientes. Após a remoção dos registros com valores faltantes, a base de dados foi reduzida para 4412 registros (Mujiono et al., 2021). As variáveis (atributos) obtidas a partir de exames de sangue laboratoriais estão discriminadas na Tabela 1 a seguir.

Tabela 1. Discriminação das variáveis disponíveis na base de dados obtida por Mujiono (2020).

Nome	Descrição
MCV	Volume Corpuscular Médio (VCM)
ERYTHROCYTE	Contagem de eritrócitos
HAEMATOCRIT	Contagem de eritrócitos multiplicado pelo VCM
HAEMOGLOBINS	Dosagem de hemoglobina
LEUCOCYTE	Contagem de leucócitos
THROMBOCYTE	Contagem de plaquetas
MCH	Hemoglobina Corpuscular média
MCHC	Concentração de Hemoglobina Corpuscular Média
AGE	Idade
SEX	Gênero

Os dados foram separados por gênero, com o intuito de verificar se os modelos aprendidos geram métricas de performance diferentes dependendo do gênero escolhido. Após a separação, 2290 amostras ficaram segregadas para o gênero masculino e 2122 para o feminino.

Os modelos foram induzidos e testados empregando os melhores parâmetros aprendidos na fase de busca e também considerando as separações na base de dados. Foram também calculados três métricas para avaliar a performance dos modelos, a saber: acurácia (Acc), precisão (Pr) e recobrimento (Re). Para

evitar superajuste dos modelos aos dados, foi utilizada a técnica de validação cruzada com 10 subconjuntos (*folds*), que consiste em separar a base de dados em 10 subconjuntos, utilizar 9 deles para indução e 1 para teste, variando a cada nova interação o conjunto selecionado para teste, de modo que este não seja utilizada simultaneamente na indução.

Para a indução dos modelos de IA/ML foi empregado o algoritmo Random Forest (RF) que emprega uma abordagem de *ensemble*, combinando modelos fracos para formar um modelo forte (o ensemble), onde cada modelo é uma estrutura de árvore e a decisão final é obtida fundindo as previsões das árvores de decisão individuais por votação majoritária (Awad e Khanna, 2015). Cada árvore possui nós, folhas e ramos, que caracterizam os valores dos atributos, as classes e a partição do espaço dos atributos, respectivamente. Para construir as árvores de decisão a partir do conjunto de indução, é utilizada uma função para medir a qualidade da divisão. Para a indução dos modelos utilizou-se Random a biblioteca Sikit-Learn (Pedregosa et al., 2011) escrita em Python e a função Gini para medir a qualidade da separação. Os demais parâmetros empregados estão discriminados na seção seguinte.

RESULTADOS E DISCUSSÃO

A distribuição de cada variável bem como as correlações entre elas estão exibidas na Figura 1. Nota-se inicialmente que apenas algumas variáveis possuem correção significativa, dentre elas HAEMOGLOBINS x HAEMATOCRIT, ERYTHROCYTE x HAEMATOCRIT, ERYTHROCYTE x HAEMOGLOBINS, MCH x MCV. Tal associação pode impactar na obtenção dos modelos de IA, pois variáveis que podem ser escritas como combinação linear uma das outras podem ser descartadas do modelo, já que apenas uma delas seria suficiente para aprender o padrão que se pretende reconhecer.

Tabela 2. Melhores parâmetros aprendidos.

Dados	Parâmetros		
	max_depth	max_leaf_nodes	n_estimators
Toda	3	3	1000
Apenas gênero masculino	3	3	100
Apenas gênero feminino	1	2	1000

A primeira etapa para essa indução consistiu da realização de uma busca pelo melhor conjunto de parâmetros do modelo. Para tanto, considerou-se todos os dados, sem separação por gênero, e também os dados com separação. A Tabela 2 mostra os melhores parâmetros.

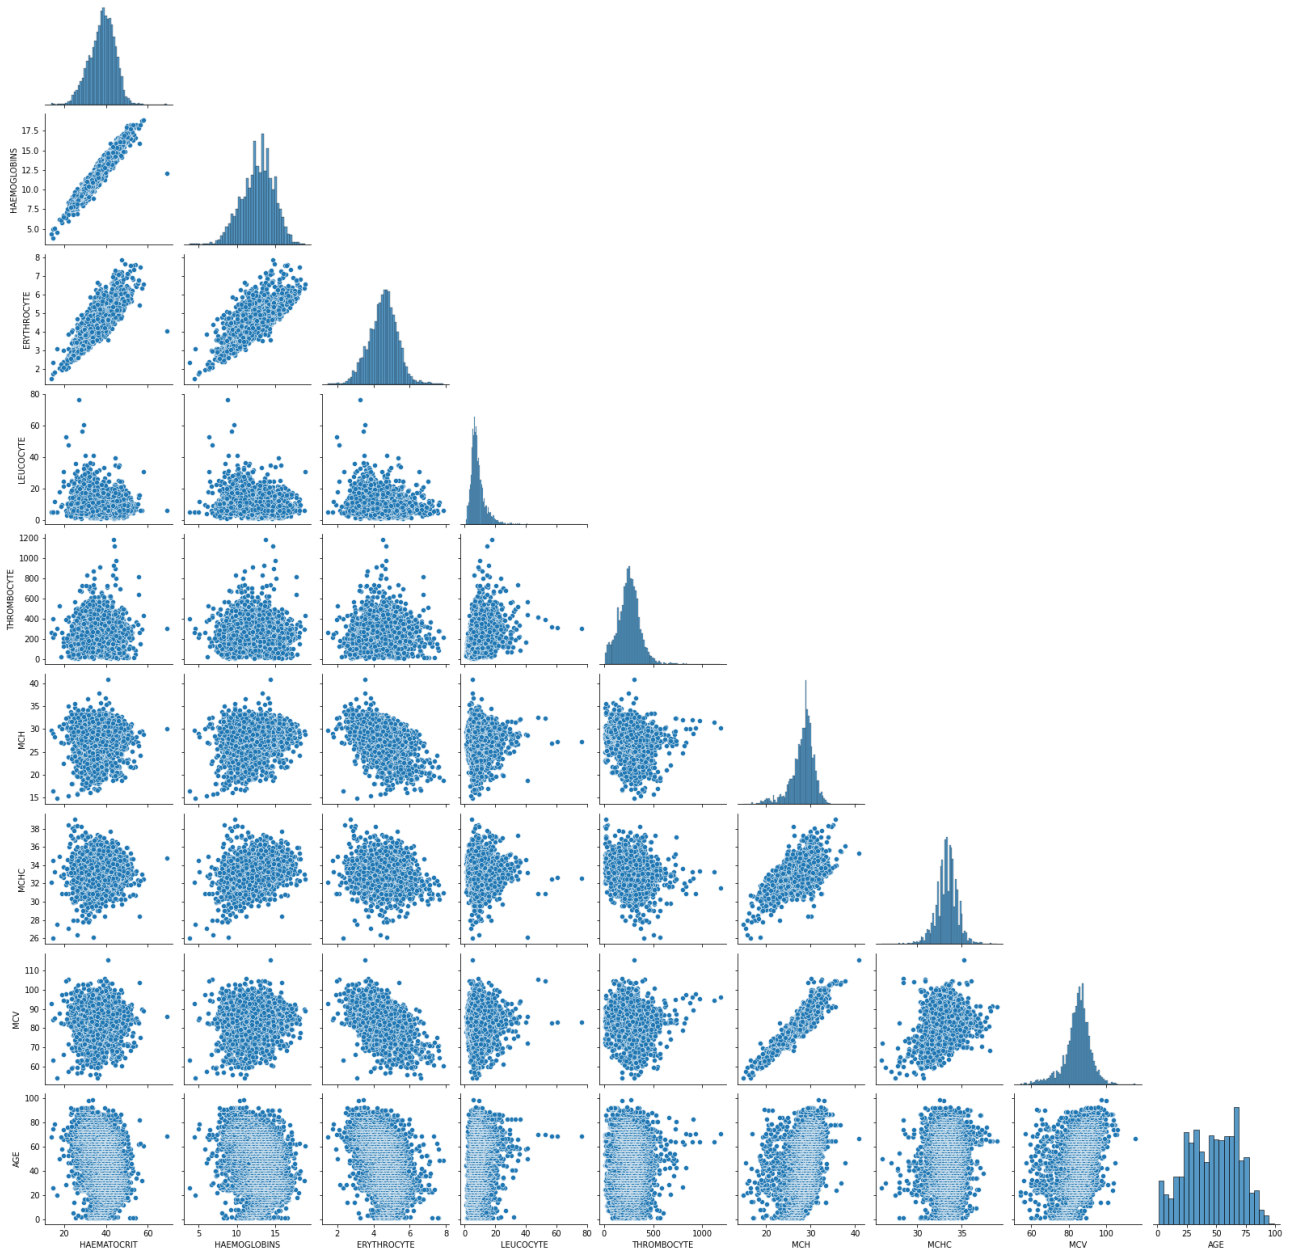


Figura 1. Distribuição e correlação entre as variáveis da base de dados de Mujiono (2020).

As Figuras 2, 3 e 4 a seguir mostram os boxplot considerando todos os dados e a separação por gênero, tanto para o conjunto de indução (figuras com título (a)) quanto para o de teste (figuras com título (b)). Como esperado, há menor variabilidade das métricas nos conjuntos de indução do que nos conjuntos de teste, em todos os casos. Isso ocorre porque as amostras de indução foram utilizadas para aprender os modelos de classificação, enquanto que as amostras dos conjuntos de teste são desconhecidas dos modelos. Portanto, espera-se que alguns dos modelos utilizados na validação cruzada tenham performance inferior a outros.

Mesmo assim, observa-se que as medianas das métricas, ao utilizar todos os dados, não se alteram muito em relação aos conjuntos de indução e teste. Por outro lado, ao empregar a separação por gênero

as medianas têm uma redução no conjunto de teste para o gênero masculino, enquanto que para o gênero feminino, em relação à métrica precisão, ocorre um acréscimo.

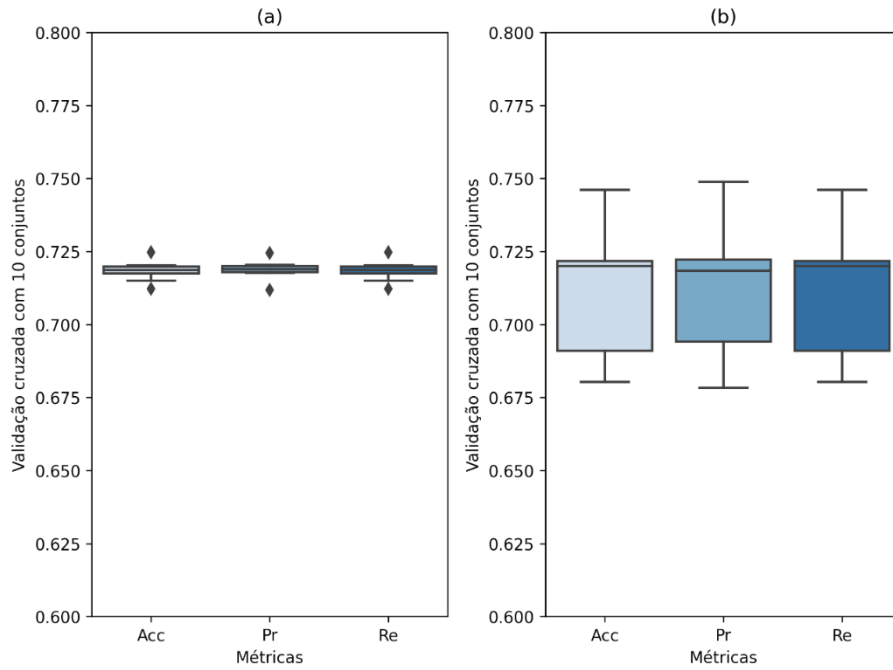


Figura 2. Estatísticas das métricas sem separação por gênero. (a) conjunto de indução e (b) conjunto de teste.

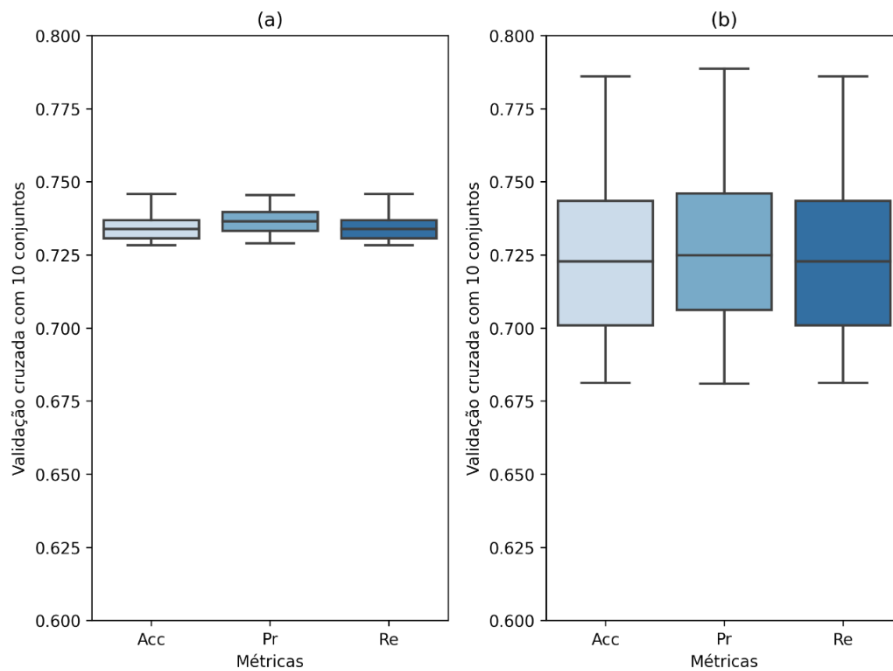


Figura 3. Estatísticas das métricas para o gênero masculino. (a) conjunto de indução e (b) conjunto de teste.

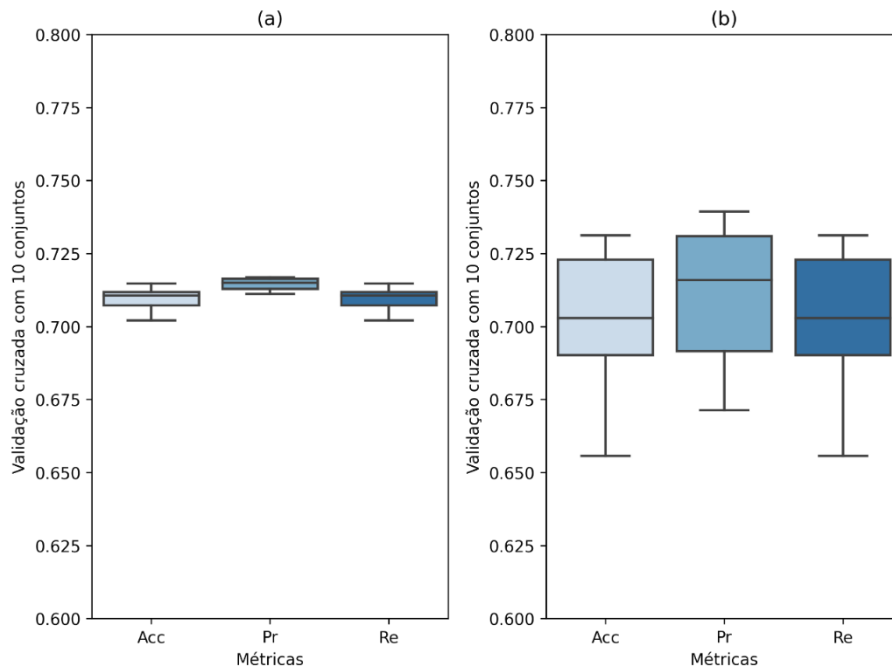


Figura 4. Estatísticas das métricas para o gênero feminino. (a) conjunto de indução e (b) conjunto de teste.

A Tabela 3 mostra apenas os resultados médios obtidos, para mais fácil comparação. A partir destes podemos observar que a separação por gênero melhora as métricas, em média, apenas em relação ao gênero masculino. Entretanto, a perda de performance considerando apenas o gênero feminino é inferior a 1%.

No entanto, devemos lembrar que ao realizar a separação por gênero, menos amostras (instâncias) há disponíveis para treinamento dos modelos. Logo, este decréscimo no número de amostras também pode influenciar nos resultados da performance.

Tabela 3. Resultados médios das métricas.

Conjunto	Sem gênero			Gênero masculino			Gênero feminino		
	Acc	Pr	Re	Acc	Pr	Re	Acc	Pr	Re
Treino	0.7184 ±0.0032	0.7188 ±0.0030	0.7184 ±0.0032	0.7345 ±0.0051	0.7366 ±0.0047	0.7345 ±0.0051	0.7097 ±0.0037	0.7146 ±0.0019	0.7097 ±0.0037
Teste	0.7117 ±0.0203	0.7131 ±0.0215	0.7117 ±0.0203	0.7253 ±0.0330	0.7297 ±0.0354	0.7253 ±0.0330	0.7022 ±0.0224	0.7100 ±0.0244	0.7022 ±0.0224

Utilizando uma característica implícita dos algoritmos que implementam árvores de decisão, como é o caso do Random Forest, pode-se computar a importância de cada atributo (variável) para os modelos aprendidos em relação a prever a alta hospitalar.

A importância do atributo gênero (SEX) para os modelos, quando consideramos a não separação dos dados, ou seja, a base de dados toda, é relativamente pequena conforme mostra o gráfico da Figura 5, que é o resultado da execução da validação cruzada com 10 *folds*.




Figura 5. Importância dos atributos considerando a validação cruzada para quando não há separação por gênero.

Também é notável, da Figura 5, que os atributos MCH, MCHC, MCV e AGE também são menos relevantes. Por outro lado, o atributo THROMBOCYTE é o mais importante de todos. Esta variável é referente às plaquetas que dependendo da sua variação pode aumentar o risco de hemorragias ou indicar infecções agudas, anemia ferropriva, dentre outras, caracterizando assim a necessidade da manutenção da internação hospitalar.

Considerando agora a separação por gênero, Figuras 6 e 7, observa-se que a importância dos atributos é análoga.




Figure 6. Importância dos atributos considerando a validação cruzada para gênero masculino.

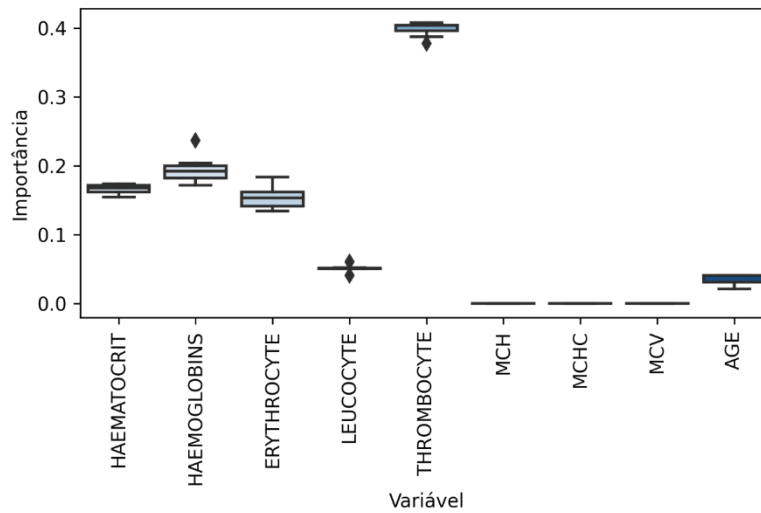


Figure 7. Importância dos atributos considerando a validação cruzada para gênero feminino.

Uma característica altamente crítica em relação aos sistemas de decisão em saúde está relacionada às falsas detecções: falsos positivos e falsos negativos. No caso em estudo a classe positiva é alta hospitalar. Sendo assim, devemos obter modelos de IA/ML que minimizem a quantidade de falsos positivos, pois conceder alta a um paciente que deveria ficar internado pode acarretar prejuízos irreparáveis para a saúde e bem estar do paciente, podendo, inclusive motivar o óbito. A quantidade de falsos negativos também é impactante, pois está relacionada às consequências devidas a uma internação prolongada, já mencionadas na introdução.

A seguir são analisadas as matrizes de confusão, novamente considerando a não separação por gênero e também sua separação. Além disso, são tomados os resultados para os conjuntos de treinamento e teste. Os valores apresentados são os valores médios calculados considerando a validação cruzada.

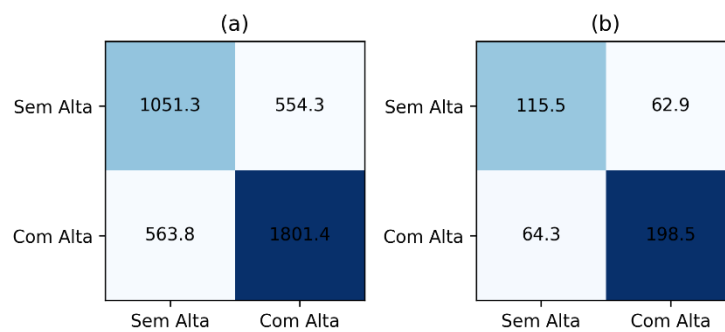


Figure 8. Matriz de confusão sem separação por gênero. (a) conjunto de indução e (b) conjunto de teste.

Nota-se na Figura 8 que ocorreram próximo de 50% de falsos positivos, ou seja, metade dos pacientes receberiam alta quando deveriam permanecer internados, se utilizássemos apenas os modelos aprendidos para decidir sobre a alta hospitalar, tanto no conjunto de treinamento quanto no de teste. Já em relação aos falsos negativos foram cerca de 32%. Por outro lado, considerando apenas os dados do gênero masculino, os falsos positivos estão em torno de 40%, logo uma redução relevante, mas ainda

assim acentuada. Já os falsos negativos no conjunto de indução permanecem em torno de 32%, tendo um acréscimo de 3% no conjunto de teste.




Figure 9. Matriz de confusão para o gênero masculino. (a) conjunto de indução e (b) conjunto de teste.

Já os falsos positivos para os dados do gênero feminino são piores que os casos acima, em torno de 53%, conforme mostra a Figura 10. Enquanto que os falsos negativos ficaram em torno de 34% e 36% nos conjuntos de indução e teste, respectivamente.




Figure 10. Matriz de confusão para o gênero feminino. (a) conjunto de indução e (b) conjunto de teste.

Todos os resultados anteriormente elencados, implicam que, embora um modelo induzido apenas para o gênero masculino tenha mostrado um pequeno acréscimo de performance, em geral, não há ganho de performance em considerar os dados separados por gênero. Ao menos, para a base de dados utilizada para este experimento. Entretanto, observou-se que ocorrem cerca de 10% menos falsos positivos e próximo de 2% menos falsos negativos ao utilizar os dados apenas do gênero masculino. Por outro lado, esse ganho de performance dos modelos induzidos com os dados do gênero masculino é perdido ao utilizar os dados somente do gênero feminino.

Em geral, os modelos aprendidos obtiveram uma acurácia de cerca de 70%, e 50% de falsos positivos. Embora os percentuais sejam baixo e alto, respectivamente, para um sistema de apoio a decisão os modelos aprendidos podem ser utilizados, pois haverão outras informações relevantes à decisão sobre a alta hospitalar que não foram consideradas nos modelos, lembrando que estes estão apenas decidindo com base nas informações do hemograma. Ou seja, existem informações implícita da decisão médica que

não foram codificadas na base de dados. Por isso, os modelos aprendidos apenas são úteis como um auxílio na tomada da decisão sobre alta hospitalar.

Mesmo assim, o refinamento dos modelos é necessário, o que será possível apenas com bases de dados maiores e também de outras localidades do globo, para que não sejam aprendidos pelos modelos padrões relativos a certas populações, a questões culturais, de alimentação, etc. Ou seja, tal abordagem evitaria modelos enviesados.

REFERÊNCIAS BIBLIOGRÁFICAS

- Anderson P, Meara J, Brodhurst S, Attwood S, Timbrell M, & Gatherer A (1988). Use of hospital beds: a cohort study of admissions to a provincial teaching hospital. *British Medical Journal*, 297(6653), 910-912.
- Awad M, & Khanna R (2015). *Efficient learning machines: theories, concepts, and applications for engineers and system designers* (p. 268). Springer Nature. DOI: 10.1007/978-3-319-20010-1.
- Bhinder B, Gilvary C, Madhukar NS, & Elemento O (2021). Artificial intelligence in cancer research and precision medicine. *Cancer discovery*, 11(4), 900-915. DOI: 10.1158/2159-8290.CD-21-0090
- Chen RJ, Lu MY, Chen TY, Williamson DF, & Mahmood F (2021). Synthetic data in machine learning for medicine and healthcare. *Nature Biomedical Engineering*, 5(6), 493-497. DOI: 10.1038/s41551-021-00751-8
- Cesar AM, & Santos BRLD (2005). Percepção de cuidadores familiares sobre um programa de alta hospitalar. *Revista brasileira de enfermagem*, 58, 647-652. DOI: 10.1590/S0034-71672005000600004
- de Abreu CCE, de Oliveira BR, Duarte MAQ, Vieira Filho J, & Villarreal, F (2017). Simple wavelet-based features for arrhythmia identification from HRV signals based on an artificial immune system. *DINCON 2017 - Conferência Brasileira de Dinâmica, Controle e Aplicações*.
- de Oliveira BR, de Abreu CCE, Duarte MAQ, & Vieira Filho J (2019). Geometrical features for premature ventricular contraction recognition with analytic hierarchy process based machine learning algorithms selection. *Computer methods and programs in biomedicine*, 169, 59-69. DOI: 10.1016/j.cmpb.2018.12.028
- Gertman PM, & Restuccia JD (1981). The appropriateness evaluation protocol: a technique for assessing unnecessary days of hospital care. *Med Care*. 1981;19(8):855-71. DOI:10.1097/00005650-198108000-00005
- Gossler FE, de Oliveira BR, Duarte MAQ, Lamblém RL, & Alvarado FV (2016). A wavelet generated from Fibonacci-coefficient polynomials and its application in cardiac arrhythmia classification. In *Proc. of XIX ENMC-National Meeting on Comp. Model. and VII ECTM-Meeting on Materials Science and Tech.*

- Landeiro F, Leal J, & Gray AM (2016). The impact of social isolation on delayed hospital discharges of older hip fracture patients and associated costs. *Osteoporosis international*, 27(2), 737-745. DOI: 10.1007/s00198-015-3293-9
- Li, JPO, Liu H, Ting DS, Jeon S, Chan RP, Kim JE, & Ting, DS (2021). Digital technology, tele-medicine and artificial intelligence in ophthalmology: A global perspective. *Progress in retinal and eye research*, 82, 100900. DOI: 10.1016/j.preteyeres.2020.100900
- Lim SC, Doshi V, Castasus B, Lim JKH, & Mamun K (2006). Factors causing delay in discharge of elderly patients in an acute care hospital. *Annals-Academy of Medicine Singapore*, 35(1), 27.
- Kiener, M. (2021). Artificial intelligence in medicine and the disclosure of risks. *Ai & Society*, 36(3), 705-713. DOI: 10.1007/s00146-020-01085-w
- Mujiono S, Nurhaida I, & Sari RP (2021). Exploratory Study of Some Machine Learning Techniques to Classify the Patient Treatment. (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, 12(2).
- McDonagh SM, Smith DH, & Goddard M (2000). Measuring appropriate use of acute beds: a systematic review of methods and results. *Health Policy*, 53(3):157-84. DOI:10.1016/S0168-8510(00)000920
- Rojas-García A, Turner S, Pizzo E, Hudson E, Thomas J, & Raine R (2017). Impact and experiences of delayed discharge: A mixed-studies systematic review. *Health Expectations*, 21(1), 41-56. DOI: 10.1111/hex.12619
- Mujiono S (2020). EHR Dataset for Patient Treatment Classification, Mendeley Data, V1. DOI: 10.17632/7kv3rctx7m.1
- Pedregosa et al. (2011). Scikit-learn: Machine Learning in Python. *JMLR* 12, 2825-2830.
- Rosenfeld, L. G. et al. (2019). Valores de referência para exames laboratoriais de hemograma da população adulta brasileira: Pesquisa Nacional de Saúde. *Revista Brasileira de Epidemiologia*, v. 22. DOI: 10.1590/1980-549720190003.supl.2.
- Silva SAD, Valácio RA, Botelho FC, & Amaral CFS (2014). Fatores de atraso na alta hospitalar em hospitais de ensino. *Revista de Saúde Pública*, 48, 314-321. DOI: 10.1590/S0034-8910.2014048004971
- Vetter N (2003). Inappropriately delayed discharge from hospital: What do we know? *BMJ*, 326(7395):927-928. DOI:10.1136/bmj.326.7395.927

Índice Remissivo

A

alta hospitalar, 132, 133, 137, 139, 140, 141, 142

C

capacitação em serviço, 14
COVID-19, 25, 26, 27, 28, 29, 30, 31, 32, 33,
34, 35
cuidado, 49

D

desigualdades, 25

E

educação em Saúde, 14, 17
enfermagem, 53, 55
eritroblastose Fetal, 12
estudos de validação, 157, 158, 159

F

fatores de risco envolvidos, 145
fitoterapia, 154, 159
flavonoides, 155, 156, 157

G

gerontologia, 49

H

hemograma, 133, 140, 142
HIV, 53, 54, 55, 57, 59, 60, 61, 62, 63, 64

I

inteligência artificial, 4

L

Letramento em Saúde, 53, 55

M

maternidade, 43

O

óleos essenciais, 156, 157, 158, 159, 163

P

Pesquisa em Enfermagem, 55
Pneumonia comunitária, 82
Preceptoria, 14, 17

R

raça, 29
Random Forest, 134, 137
Rede de Atenção Psicossocial, 146, 147, 163

S

sexo, 29
Streptococcus pneumoniae, 69, 74, 76, 78, 79

U

uso popular, 152, 156, 158, 159

Sobre a organizadora



Aris Verdecia Peña

Médica, graduada em Medicina (1993) pela Universidad de Ciencias Médica de Santiago de Cuba. Especialista em Medicina General Integral (1998) pela Universidad de Ciencias Médica de Santiago de Cuba. Especializada em Medicina en Situaciones de Desastre (2005) pela Escola Latinoamericana de Medicina em Habana. Diplomada em Oftalmología Clínica (2005) pela Universidad de Ciencias Médica de Habana. Mestrado em Medicina Natural e Bioenergética (2010), Universidad de Ciencias Médicas de Santiago de Cuba, Cuba. Especializada em Medicina Familiar (2016) pela Universidade de Minas Gerais, Brasil. Profesora e Instructora da Universidad de Ciencias Médicas de Santiago de Cuba (2018). Ministra Cursos de pós-graduação: curso Básico Modalidades de Medicina Tradicional em urgências e condições de desastres. Participou em 2020 na Oficina para Enfrentamento da Covi-19. Atualmente, possui 11 artigos publicados, e 12 organizações de e-books



Pantanal Editora

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000

Nova Xavantina – Mato Grosso – Brasil

Telefone (66) 99682-4165 (Whatsapp)

<https://www.editorapantanal.com.br>

contato@editorapantanal.com.br