

Web App para a predição de internação em Unidade de Terapia Intensiva por covid-19

Web App for prediction of hospitalisation in Intensive Care Unit by covid-19

Web App para la predicción de hospitalización em la Unidad de Cuidados Intensivos por covid-19

Greici Capellari Fabrizzio¹

ORCID: 0000-0002-3848-5694

Alacoque Lorenzini Erdmann¹

ORCID: 0000-0003-4845-8515

Lincoln Moura de Oliveira²

ORCID: 0000-0001-6016-745X

¹ Universidade Federal de Santa Catarina. Florianópolis, Santa Catarina, Brasil.

² Universidade Federal do Ceará. Fortaleza, Ceará, Brasil.

Como citar este artigo:

Fabrizzio GC, Erdmann AL, Oliveira LM. Web App for prediction of hospitalisation in Intensive Care Unit by covid-19. Rev Bras Enferm. 2023;76(6):e20220740. <https://doi.org/10.1590/0034-7167-2022-0740pt>

Autor Correspondente:

Greici Capellari Fabrizzio

E-mail: greicicapellari@gmail.com



EDITOR CHEFE: Antonio José de Almeida Filho

EDITOR ASSOCIADO: Rosane Cardoso

Submissão: 05-01-2023 **Aprovação:** 23-07-2023

RESUMO

Objetivo: Desenvolver um Web App a partir de um modelo preditivo para estimar o risco de internação de pacientes com covid-19 em UTI. **Métodos:** Realizou-se uma pesquisa aplicada de produção tecnológica com o desenvolvimento do Streamlit a partir do Python, considerando o modelo de árvore de decisão que apresentou o melhor desempenho (AUC 0.668). **Resultados:** A partir das variáveis associadas à Enfermagem de Precisão, o Streamlit estratifica os pacientes internados nas unidades clínicas com maior probabilidade de internação em Unidade de Terapia Intensiva, funcionando como uma ferramenta de apoio à tomada de decisão dos profissionais de saúde. **Considerações finais:** A performance do modelo pode ter sido influenciada pelo início da vacinação no período de coleta de dados, no entanto, o Web App via Streamlit mostrou-se uma ferramenta viável para a apresentação dos resultados de pesquisa, devido à facilidade de entendimento por parte dos enfermeiros e pelo potencial de apoio à decisão clínica.

Descritores: Invenções; Predição; Inteligência Artificial; Covid-19; Medicina de Precisão.

ABSTRACT

Objective: To develop a Web App from a predictive model to estimate the risk of Intensive Care Unit (ICU) admission for patients with covid-19. **Methods:** An applied technological production research was carried out with the development of Streamlit using Python, considering the decision tree model that presented the best performance (AUC 0.668). **Results:** Based on the variables associated with Precision Nursing, Streamlit stratifies patients admitted to clinical units who are most likely to be admitted to the Intensive Care Unit, serving as a decision-making support tool for healthcare professionals. **Final considerations:** The performance of the model may have been influenced by the start of vaccination during the data collection period, however, the Web App via Streamlit proved to be a feasible tool for presenting research results, due to the ease of understanding by nurses and its potential for supporting clinical decision-making.

Descriptors: Inventions; Forecasting; Artificial Intelligence; Covid-19; Precision Medicine.

RESUMEN

Objetivo: Desarrollar una Web App a partir de un modelo predictivo para estimar el riesgo de ingreso a la Unidad de Cuidados Intensivos (UCI) para pacientes con covid-19. **Métodos:** Se realizó una investigación de producción tecnológica aplicada con el desarrollo de Streamlit utilizando Python, considerando el modelo de árbol de decisiones que presentó el mejor rendimiento (AUC 0.668). **Resultados:** Basado en las variables asociadas con la Enfermería de Precisión, Streamlit estratifica a los pacientes ingresados en unidades clínicas que tienen más probabilidades de ser admitidos en la Unidad de Cuidados Intensivos, sirviendo como una herramienta de apoyo para la toma de decisiones para los profesionales de la salud. **Consideraciones finales:** El rendimiento del modelo puede haber sido influenciado por el inicio de la vacunación durante el período de recolección de datos. La Web App a través de Streamlit demostró ser una herramienta factible para presentar los resultados, debido a la facilidad de comprensión y su potencial para apoyar la toma de decisiones clínicas.

Descriptorios: Invencciones; Predicción; Intelligencia Artificial; Covid-19; Médecine de Précision.

INTRODUÇÃO

Os pacientes infectados pela covid-19 apresentam evolução clínica variada da doença, com sinais e sintomas que oscilam desde quadros leves até formas moderadas e graves da infecção. Entre os pacientes que desenvolvem casos moderados, 20 a 30% necessitam de cuidados em leito clínico hospitalar e de 5 a 25% dos pacientes que desenvolvem casos graves da doença requerem cuidados em uma Unidade de Terapia Intensiva (UTI)⁽¹⁻²⁾.

Existem alguns estudos que propõem o desenvolvimento de modelos de inteligência artificial para prever a probabilidade de pacientes infectados pela covid-19 evoluírem para um agravamento no quadro clínico e necessitarem de internação em UTI⁽¹⁻³⁾. Essas tecnologias fornecem predições estatísticas precisas que auxiliam na tomada de decisão dos profissionais da saúde⁽⁴⁾. Entretanto, um dos desafios consiste em disponibilizar os resultados das pesquisas de modo que os profissionais de saúde possam fazer uso deles. Uma das ferramentas que encontramos para essa finalidade foi o *Streamlit*, um *Web App* que utiliza a biblioteca Python de código aberto para facilitar a criação e o compartilhamento de aplicativos Web personalizados, a partir de aprendizado de máquina e ciência de dados⁽⁵⁾. Não foram encontrados, na literatura científica, relatos de aplicações de uso para apresentação dos resultados de pesquisa científica, em que a calculadora web possibilita a realização de simulações, pelos profissionais de saúde, para estimar o risco de internação de pacientes com covid-19, em UTI.

Essas técnicas de inteligência artificial contribuem para melhorias no cuidado de Enfermagem e na atenção à saúde como um todo, tendo como referencial teórico a Enfermagem de Precisão, que auxilia provedores a personalizar o atendimento⁽⁶⁾. Nesse sentido, a Enfermagem de Precisão, conceito derivado da Medicina de Precisão, caracteriza-se como o cuidado de enfermagem fundamentado em características e necessidades únicas de um paciente, considerando especificidades biológicas, biomarcadores clínicos e laboratoriais, patologias de base, hábitos de vida (fenótipo), determinantes sociais e o contexto em que o paciente está inserido (epigenética)⁽⁶⁻⁸⁾. A identificação de biomarcadores amplia as possibilidades para os enfermeiros identificarem quais mecanismos biológicos subjacentes estão por trás de uma condição de saúde ou de um sintoma específico e, a partir disso, aplicar intervenções mais precisas para a recuperação de saúde desse indivíduo⁽⁷⁾.

O auxílio de ferramentas de precisão ajuda os profissionais de saúde a estratificar os pacientes que demandam maior necessidade de atendimento personalizado, bem como a identificação de pacientes com maior risco e, portanto, que carecem de um cronograma de acompanhamento diferenciado. Outro ponto que pode ser útil é na orientação de discussões com famílias sobre resultados a longo prazo, como na Síndrome Pós-covid-19 ou Covid longa⁽⁹⁻¹⁰⁾.

OBJETIVO

Desenvolver um *Web App* a partir de um modelo preditivo para estimar o risco de internação de pacientes com covid-19 em UTI.

MÉTODOS

Trata-se de uma pesquisa aplicada de produção tecnológica do *Web App* para predição da internação em Unidade de Terapia Intensiva por covid-19, desenvolvida de novembro de 2021 a março de 2022. A pesquisa aplicada caracteriza-se pela busca de uma solução imediata para a resolução de um problema atual⁽¹¹⁾. *Web Apps* são ferramentas computacionais que vão desde simples páginas na Web até sites completos com funcionalidades especializadas, e que processam uma série de informações. Dentre as funcionalidades, está a possibilidade de integração com bancos de dados e o desenvolvimento de aplicações em determinadas áreas⁽¹²⁾.

O estudo faz parte da tese de doutorado intitulada: "Enfermagem de Precisão e Inteligência Artificial: biomarcadores para a predição da internação de pacientes infectados pela covid-19 em Unidade de Terapia Intensiva", desenvolvida no Programa de Pós-Graduação em Enfermagem da Universidade Federal de Santa Catarina.

O método de produção tecnológica do *Web App* foi dividido em três etapas, apresentadas a seguir:

1. Recrutamento de informações dos pacientes

Participaram do estudo 547 pacientes diagnosticados com covid-19 que foram internados em cinco hospitais universitários brasileiros: um hospital na região Sul, dois hospitais na região Sudeste, um hospital na região Nordeste e um hospital no Norte do país.

Os dados foram coletados por meio de entrevistas telefônicas, realizadas nos meses de abril a dezembro de 2021, com base na listagem disponibilizada pelos hospitais universitários. No primeiro contato, os pacientes eram convidados a participar do estudo após a leitura do Termo de Consentimento Livre e Esclarecido. Quando o paciente aceitava participar da pesquisa, era iniciada a gravação da entrevista e aplicados os questionários *Care Transitions Measure* (CTM-15) - que avalia a transição do cuidado hospitalar para o domicílio - e *Patient Measure Of Safety* (PMOS) - que avalia a segurança do paciente no contexto hospitalar. Em seguida, era aplicado um questionário sociodemográfico estruturado para caracterizar os pacientes. As respostas foram registradas na plataforma *Google Forms*⁽¹³⁻¹⁴⁾.

Os critérios de seleção foram: teste reagente para SARS-CoV-2 e internação hospitalar superior a 72h. Quando os pacientes estavam debilitados ou apresentavam alterações físicas, psicológicas e cognitivas, um responsável, familiar ou cuidador era convidado a responder, uma vez que o instrumento CTM-15 admite a resposta do cuidador ou responsável. Porém, os pacientes com os quais se tentou contato para responder às informações sociodemográficas associadas ao PMOS, que estavam debilitados ou sem condições psicológicas para responder à pesquisa, foram excluídos do estudo, já que o instrumento só pode ser respondido pelo próprio paciente, que vivenciou todas as situações que influenciam na sua segurança. Também foram excluídos do estudo menores de 18 anos, pacientes que não se comunicavam fluentemente em português, pacientes que não receberam alta para casa, pacientes que foram a óbito após a alta, e pacientes que foram reinternados após a alta.

Foram analisadas 23 variáveis associadas à Enfermagem de Precisão, incluindo: informações sociodemográficas dos pacientes, como idade, gênero, grau de instrução e raça; biomarcadores clínicos, como dias de internação em UTI, doença respiratória crônica, hipertensão arterial sistêmica, doenças cardiovasculares, diabetes mellitus, doenças renais, obesidade, câncer, febre, fadiga, falta de ar, tosse, perda de olfato e paladar, dor de cabeça, dor no corpo, náuseas e vômito, e diarreia; hábitos de vida (fenótipo), como histórico de tabagismo; e determinantes sociais e contexto (epigenética), como renda familiar e número de pessoas residentes no domicílio. As variáveis excluídas do estudo foram: município de residência, dias de internação e uso de ventilação mecânica, devido à possibilidade de evidenciar o desfecho ou por não acrescentarem valor para a modelagem.

A padronização das variáveis numéricas (idade e número de pessoas residentes no domicílio) ocorreu pela remoção da média e escalonamento em torno da variância unitária. As demais variáveis foram consideradas categóricas e transformadas em valores binários 0 ou 1, por meio da técnica de *one-hot encoding*, para que os dados pudessem ser modelados como valores numéricos. Após a realização dessas técnicas de padronização, foram imputados os valores ausentes para completar o banco de dados.

O banco de dados foi composto por 309 pacientes que passaram pela UTI e 238 que não passaram. Essa discrepância entre as classes pode facilitar o aprendizado da classe com maior número de registros. Por essa razão, utilizou-se da técnica de subamostragem, *undersampling*, para realizar o equilíbrio entre as classes. Por meio de uma seleção aleatória, foram misturados os dados das duas classes e, posteriormente, realizado um novo agrupamento a partir da classe com o menor número de registros, restando 476 pacientes.

2. Treinamento e validação dos modelos

Os dados foram divididos aleatoriamente em 75% (357 pacientes) para treinamento do modelo e 25% (119 pacientes) para teste. Foram testados os seguintes modelos de inteligência artificial: rede neural, *AdaBoost*, regressão logística, floresta aleatória, *K Nearest Neighbor*, *Naive Bayes*, *Support Vector Machine* e árvore de decisão. Os oito modelos testados foram avaliados por meio da validação cruzada dos dados em cinco *fold*, e das métricas: Área Acima da Curva (AUC), sensibilidade e especificidade. A técnica *k-fold*, contextualizada para cinco *fold* anteriormente, refere-se à quantidade de iterações e de grupos em que a amostra foi dividida de forma aleatória, nesse caso, cinco iterações e cinco grupos. A cada iteração, quatro grupos são destinados para treino e um grupo é destinado para teste, na próxima iteração esses grupos são alterados e a acurácia final é calculada a partir da média das acurácias das iterações⁽¹⁵⁾. A AUC refere-se à maior área sob a curva Característica de Operação do Receptor (ROC) e correlaciona as métricas de sensibilidade e especificidades mensuradas pelo classificador, variando de 0.585 a 0.668, sendo a árvore de decisão o modelo que apresentou o melhor desempenho (AUC 0.668)⁽¹⁵⁾. As três primeiras variáveis que mais influenciaram na decisão do modelo foram: idade, internação no hospital da Universidade Federal do Amazonas e o número de pessoas residentes no mesmo domicílio, seguidas das demais variáveis.

A sensibilidade é avaliada por meio do cálculo do número de pacientes classificados como verdadeiro positivo, dividido pelo somatório de verdadeiro positivo e falso negativo, avaliando o percentual de resultados positivos do modelo. Enquanto a especificidade caracteriza-se pelo cálculo do número de pacientes classificados como verdadeiro negativo dividido pelo somatório de verdadeiro negativo e falso positivo, avaliando a capacidade do modelo de detectar resultados negativos⁽¹⁵⁾.

De acordo com a matriz de confusão gerada a partir dos dados de teste do modelo de árvore de decisão, o modelo classificou 119 pacientes (25% do banco de dados) em cada uma das classes. Foi evidenciado que 32,77% (39 pacientes) foram classificados como verdadeiros positivos, 31,93% (38 pacientes) classificados como verdadeiros negativos, 18,49% (22 pacientes) classificados como falsos positivos e 16,81% (20 pacientes) classificados como falsos negativos. Para esse modelo, buscou-se minimizar ao máximo os pacientes classificados como falso negativo, ou seja, quando o paciente apresenta necessidade de internação em leito de UTI e o modelo classifica como não apresentando probabilidade de ir para a UTI, considerando as implicações práticas dessa classificação.

3. Desenvolvimento do Web App

A equipe de desenvolvimento do *Web App* foi composta por um grupo multidisciplinar de três pessoas: um engenheiro de software e duas enfermeiras, ambas especialistas em gestão em saúde, sendo que uma delas possui expertise em informática em saúde. As enfermeiras contribuíram nas etapas de coleta de dados, definição das variáveis de estudo e das melhores métricas para avaliação dos modelos. O desenvolvedor programou o código-fonte em Python, onde a padronização das variáveis foi realizada, bem como o treinamento e os testes dos modelos para o posterior desenvolvimento do *Streamlit*. Ele também criou o repositório no *GitHub*.

O fluxograma de construção do *Web App*, apresentado na Figura 1, evidencia o caminho percorrido desde a base de dados, o treinamento e o teste dos modelos até a construção do *Web App*.

O trabalho foi desenvolvido em linguagem de programação *Python*, onde os melhores modelos foram identificados e, posteriormente, o *Streamlit* foi executado. Inicialmente, o comando *'streamlit run'* foi executado em um *script Python*, o que ativou um servidor *Streamlit* local e o aplicativo foi aberto em uma nova guia no navegador padrão da *Web*.

O aplicativo pode ser personalizado com textos, gráficos, figuras, tabelas e outros elementos necessários para ajustar a aplicação de acordo com as necessidades. Essas alterações podem ser feitas modificando o código-fonte e salvando o arquivo de origem. O *Streamlit* detecta as alterações e pergunta se o usuário gostaria de aplicá-las. Isso permite uma interação rápida entre o código que está sendo desenvolvido e a visualização da aplicação⁽⁵⁾.

Os dados são armazenados no *GitHub* em uma planilha do *Microsoft Office Excel* e são acessados pelo *Streamlit*. A atualização dos dados ocorre mediante a atualização da planilha Excel, de modo que a ferramenta consulta o arquivo e atualiza suas saídas (previsões) para novas entradas de dados (novo paciente).

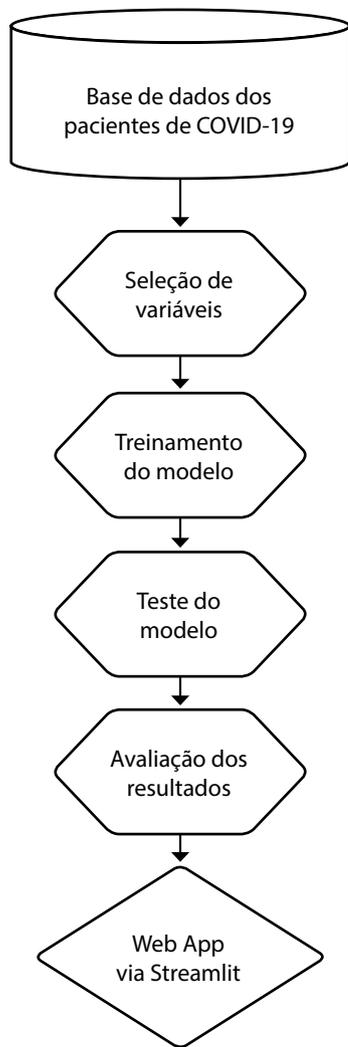


Figura 1 – Fluxograma de construção do Web App, Florianópolis, Santa Catarina, Brasil, 2022

O estudo foi conduzido de acordo com as diretrizes de ética nacionais e internacionais e aprovado pelo Comitê de Ética em Pesquisa da Universidade Federal de Santa Catarina. Em relação aos princípios éticos da pesquisa com seres humanos, aos participantes do estudo foi apresentado o Termo de Consentimento Livre e Esclarecido, que foi assinado por todos. Além disso, o estudo seguiu a orientação do Relatório Transparente de um Modelo de Previsão Multivariável para Prognóstico ou Diagnóstico Individual (TRIPOD), para relatar pesquisas de desenvolvimento, validação ou atualização de modelo de previsão, para fins diagnósticos ou prognósticos⁽¹⁶⁾.

RESULTADOS

O *Web App* foi desenvolvido com base na árvore de decisão, que se destacou como o melhor modelo de inteligência artificial identificado. A descrição do código e a execução do *Streamlit* foram realizadas em *Python*.

Na interface do usuário, conforme demonstrado na Figura 2, é possível visualizar uma apresentação visual e interativa das

variáveis associadas à Enfermagem de Precisão. Por exemplo, sinais e sintomas da covid-19, informações demográficas e doenças prévias dos pacientes que compõem o banco de dados podem ser visualizados. A exploração dos dados possibilita ao enfermeiro conhecer quais são as características dos pacientes que compõem o estudo. Além disso, as características por hospital, ou até de mais de um hospital, podem ser exploradas conforme o comando selecionado pelo profissional.

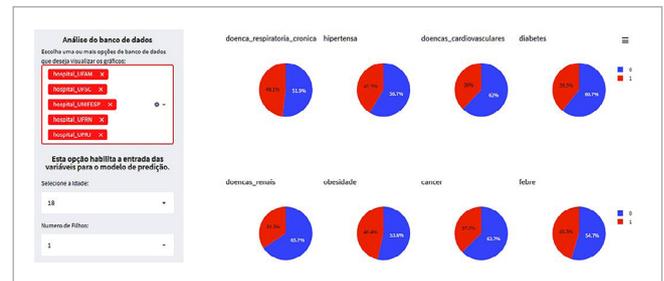


Figura 2 – Exploração visual e interativa do banco de dados no Web App, Florianópolis, Santa Catarina, Brasil, 2022

Vamos agora a um exemplo de aplicação da ferramenta. O enfermeiro do plantão, na unidade de internação para covid-19, recebe um paciente do sexo masculino, de 37 anos, branco, com ensino superior completo, dois filhos, renda familiar entre R\$ 5.000 e R\$ 10.000, que não apresenta comorbidades. Ele apresenta os seguintes sintomas: falta de ar, tosse e febre. O enfermeiro gostaria de caracterizar a gravidade do quadro para planejamento da assistência de enfermagem e, em caso de necessidade, solicitar leito em UTI. Após a coleta de informações do paciente, ele insere as variáveis no *Web App* e visualiza uma predição da probabilidade de internação em UTI para o referido paciente.

Conforme o exemplo apresentado anteriormente, o enfermeiro pode se valer do *Web App* como uma ferramenta de apoio à tomada de decisão. No menu à esquerda da aplicação, é possível inserir as variáveis relacionadas à Enfermagem de Precisão, que caracterizam o perfil clínico de um novo paciente internado, conforme demonstrado na Figura 3.

A partir dos dados clínicos do paciente, a predição é processada com base no modelo de inteligência artificial treinado a partir de dados de pacientes anteriores. Esse modelo classifica a probabilidade de o novo paciente necessitar ou não de internação na UTI. A Figura 4 apresenta um resultado que indica uma probabilidade de 68% de o paciente não necessitar de internação em UTI, com uma acurácia do modelo de 64,7%.

Por outro lado, a Figura 5 apresenta uma classificação pelo modelo de predição na qual o paciente tem uma probabilidade de 68% de necessitar de internação na UTI (classe 1). Nas classificações em que o resultado indica alta probabilidade de necessidade de internação na UTI, o resultado aparece em uma escala de cores que varia do verde (baixa probabilidade) ao vermelho (alta probabilidade).

Além da probabilidade de necessidade de internação na UTI, após a predição, a ferramenta também mostra as variáveis que tiveram maior influência no modelo e a matriz de confusão.

O desenvolvimento desta inovação tecnológica se mostrou uma solução eficaz para a apresentação dos resultados de uma

pesquisa proveniente de uma tese de doutorado, demonstrando o potencial do *Web App*, construído via *Streamlit*, para realizar predições acerca da probabilidade de internação de pacientes infectados pela covid-19 em Unidade de Terapia Intensiva, a partir do referencial teórico da Enfermagem de Precisão. Além das funcionalidades de estratificação de risco para internação em Unidade de Terapia Intensiva, também demonstrou potencial para o armazenamento de informações referentes às simulações realizadas no *Web App*, o que pode ser utilizado no futuro para melhorar o desempenho preditivo do modelo. O registro dessas informações indica as mudanças que podem ocorrer no comportamento da doença ao longo do tempo.

Esta opção habilita a entrada das variáveis para o modelo de predição.

Selecione a idade: 37

Numero de Filhos: 2

Escolha o hospital de origem do paciente: hospital_UFSC

Preencha o sexo do paciente: Masc

Preencha a instrução do paciente: sup_com

Preencha a raça do paciente: branca

Preencha a renda do paciente: 5_10_mil

Preencha se paciente fumante: nao_fumante

Selecione um ou mais sintomas em caso da existencia: Choose an option

Realizar a análise

Figura 3 – Inserção de dados clínicos do paciente no Web App, Florianópolis, Santa Catarina, Brasil, 2022



Figura 4 – Simulação de caso em que o paciente apresenta baixa probabilidade de necessitar de internação em UTI, Florianópolis, Santa Catarina, Brasil, 2022

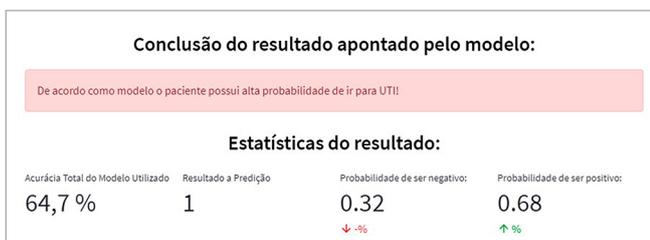


Figura 5 – Simulação de caso em que o paciente apresenta alta probabilidade de necessitar de internação em UTI, Florianópolis, Santa Catarina, Brasil, 2022

DISCUSSÃO

Dos 08 modelos testados, a árvore de decisão foi o que apresentou a melhor AUC (0.668), sendo parametrizada da seguinte forma: induziu-se a árvore binária, estabeleceu-se o número mínimo de casos em galhos em 5 e a profundidade máxima das árvores em 12. Além disso, foi parametrizada para não dividir subconjuntos menores que 7 e classificada para parar quando a maioria alcançava 99%. A parametrização de árvores com a profundidade máxima de 12 evita o *overfitting*, ou seja, o sobreajuste que pode ocorrer em árvores com muitos ramos.

A árvore de decisão é caracterizada por nós (folhas) e ramos. Cada nó representa um teste realizado em um atributo e os ramos são os resultados desses testes. Assim, parte dos dados segue por um ramo e a outra por outro. Dessa forma, o nó seguinte recebe uma quantidade menor de amostras do que o nó anterior⁽¹⁷⁾. A árvore de decisão é um dos algoritmos de aprendizado de máquina mais elementares, o que facilita o entendimento por parte dos profissionais de saúde, pois a interpretabilidade e a explicabilidade do modelo são evidentes, tornando clara a forma como o modelo classifica os pacientes.

Além disso, acredita-se que o desempenho do modelo de árvore de decisão (AUC 0.668) pode estar relacionado a uma variável importante que não foi considerada neste estudo: a situação vacinal dos pacientes. Sabemos que a vacinação reduz os casos graves de covid-19, podendo chegar a uma redução de 65,6% das internações em UTI em pacientes vacinados⁽¹⁸⁾. Em pacientes com o esquema vacinal completo, a probabilidade de internação em UTI reduz em 48,8%, a probabilidade de utilização de ventilador mecânico é ainda menor, chegando a 55,4%, e eles apresentam 22,6% menos probabilidade de óbito. Os pacientes vacinados costumam ficar hospitalizados por períodos mais curtos, enquanto os pacientes não vacinados ficam afastados do trabalho por períodos maiores⁽¹⁹⁾.

Em relação ao *Streamlit*, *Web App* escolhido para o estudo, estudos preditivos anteriores realizados na área da saúde utilizaram o *Streamlit* como uma ferramenta para disponibilizar o melhor modelo de inteligência artificial para uso dos profissionais. Um estudo retrospectivo realizado na China incluiu 385 participantes para a predição do risco de vazamento ósseo de polimetilmetacrilato líquido injetado em pacientes com fraturas por compressão vertebral osteoporóticas submetidos à vertebroplastia percutânea. A partir de variáveis clínicas, detalhes cirúrgicos e características basais dos pacientes internados com ou sem vazamento, eles desenvolveram um modelo de inteligência artificial para avaliar o risco de um possível vazamento no pós-operatório de pacientes submetidos à vertebroplastia percutânea⁽²⁰⁾.

Outra pesquisa de coorte retrospectiva incluiu 103 meninos diagnosticados com válvula de uretra posterior. Os pacientes foram acompanhados por 5,7 anos, considerando que características renais e anatômicas precoces podem ser preditivas para identificação de progressão futura para doença renal crônica, terapia de substituição renal e cateterismo intermitente⁽⁹⁾. A aplicação foi mencionada como uma ferramenta simples, fácil de usar e intuitiva para enfermeiros e profissionais da saúde⁽⁴⁾. Aplicações móveis, como o *Web App*, permitem a conexão entre um dispositivo móvel e conteúdo baseado na web por meio de

um navegador especificamente planejado para uma determinada finalidade, neste caso, a predição da internação de pacientes infectados pela covid-19 em Unidade de Terapia Intensiva⁽¹²⁾.

Entretanto, quando se trata de um *Web App* preditivo para uso na prática clínica, é necessário cuidado para não solicitar muitas informações do paciente (variáveis), uma vez que não é viável para o profissional inserir uma grande quantidade de variáveis em uma situação que demanda uma rápida tomada de decisão por parte da equipe⁽³⁾. Nesse sentido, foram consideradas 23 variáveis preditoras, as quais são rapidamente coletadas na prática clínica.

A construção da aplicação foi viabilizada graças à junção de conhecimentos entre as áreas de engenharia e saúde. Nesse caso específico, contou-se com o conhecimento de enfermeiras, que compartilharam informações científicas, teóricas e práticas relacionadas à atuação na área de saúde, para o delineamento do aplicativo com um engenheiro de software, responsável pelo desenvolvimento do código. Essa complementaridade de saberes direciona o projeto, pois promove o encontro entre as necessidades dos profissionais de saúde e as possibilidades das tecnologias. Essas estratégias favorecem a adoção da ferramenta na prática profissional da enfermagem⁽⁴⁾.

Nesse sentido, o *Web App* apresenta como potencialidade o desenvolvimento de habilidades relacionadas à construção de softwares por profissionais de enfermagem e saúde. Além disso, na medida em que passam a utilizá-la, torna-se uma aliada à prática clínica, auxiliando na tomada de decisão dos profissionais de saúde. Por outro lado, os desafios relacionados à construção desse tipo de tecnologia podem estar relacionados à necessidade de capacitação profissional em saúde digital e à resistência dos próprios profissionais de saúde para a construção desse tipo de projeto.

CONSIDERAÇÕES FINAIS

O algoritmo de árvore de decisão apresentou a melhor AUC (0.668) para a predição da internação de pacientes infectados pela covid-19 em Unidade de Terapia Intensiva, razão pela qual foi o modelo carregado no *Streamlit*. A performance do modelo pode ter sido influenciada pelas mudanças no comportamento da doença, como o surgimento de novas variantes com variáveis preditoras diferenciadas e o início da vacinação no período de

coleta de dados. Assim, sugere-se a realização de novos estudos com a análise dessas variáveis.

O *Web App* via *Streamlit* facilita a construção e o funcionamento de ferramentas em relação a outros métodos, possibilitando uma melhor compreensão por parte dos profissionais de saúde e demonstrando potencial como uma ferramenta de apoio à tomada de decisão clínica. Isso pode estimular profissionais das áreas de saúde e tecnologia a desenvolver soluções semelhantes ajustadas às suas necessidades e campos de conhecimento. Nesse sentido, a interdisciplinaridade foi uma das premissas do estudo: a formação de uma equipe composta por enfermeiras e um engenheiro de software favoreceu a junção de habilidades, onde cada profissional contribuiu com a sua expertise para a construção conjunta da ferramenta.

Além disso, é possível armazenar as simulações realizadas na calculadora e, posteriormente, utilizá-las para melhorar a performance preditiva do modelo. A partir de novos dados, podem ser capturadas as mudanças de comportamento ao longo do tempo, as quais influenciam na resposta das variáveis e, consequentemente, na performance do modelo.

O estudo apresenta fragilidades no sentido de necessidade de validação pelos usuários da ferramenta, pacientes, profissionais de saúde e gestores. Sugere-se também a continuidade do projeto para tornar a aplicação *Web* integrada ao prontuário eletrônico do paciente de forma interoperável.

FOMENTO

O autor Fabrizio GC recebeu bolsa de doutorado do Programa de Bolsas Universitárias de Santa Catarina (UNIEDU/FUMDES). O estudo está inserido em um macroprojeto de pesquisa que recebeu financiamento proveniente da chamada MCTI/CNPq/CT-Saúde/MS/SCTIE/Decit n° 07/2020 e chamada pública FAPESC n° 004/2020.

CONTRIBUIÇÕES

Fabrizio GC, Erdmann AL e Oliveira LM contribuíram com a concepção ou desenho do estudo/pesquisa. Fabrizio GC e Oliveira LM contribuíram com a análise e/ou interpretação dos dados. Fabrizio GC, Erdmann AL e Oliveira LM contribuíram com a revisão final com participação crítica e intelectual no manuscrito.

REFERÊNCIAS

1. Cheng FY, Joshi H, Tandon P, Freeman R, Reich DL, Mazumdar M, et al. Using Machine Learning to Predict ICU Transfer in Hospitalized COVID-19 Patients. *J Clin Med*. 2020;6(9):1668. <https://doi.org/10.3390/jcm9061668>
2. Covino M, Sandroni C, Santoro M, Sabia L, Simeoni B, Bocci MG, et al. Predicting intensive care unit admission and death for COVID-19 patients in the emergency department using early warning scores. *Resuscitation*. 2020;156:84–91. <https://doi.org/0.1016/j.resuscitation.2020.08.124>
3. Aznar-Gimeno R, Esteban LM, Labata-Lezaun G, Del-Hoyo-Alonso R, Abadia-Gallego D, Paño-Pardo JR, et al. A clinical decision web to predict ICU admission or death for patients hospitalised with COVID-19 using machine learning algorithms. 2021;18(16):8677. <https://doi.org/10.3390/ijerph18168677>
4. Gonçalves LS, Amaro MLM, Romero ALM, Schamne FK, Fressatto JL, Bezerra CW. Implementation of an Artificial Intelligence Algorithm for sepsis detection. *Rev Bras Enferm*. 2020;73(3):e20180421. <https://doi.org/10.1590/0034-7167-2018-0421>
5. Streamlit. The fastest way to build and share data apps [Internet]. 2022 [cited 2022 Apr 4]. Available from: <https://streamlit.io/>

6. Yuan C. Precision Nursing: New Era of Cancer Care. *Cancer Nurs.* 2015;38(5):333–334. <https://doi.org/10.1097/NCC.0000000000000290>
7. Corwin EJ, Ferranti EP. Integration of biomarkers to advance precision nursing interventions for family research across the life span. *Nurs Outlook.* 2016;64(4):292–8. <https://doi.org/10.1016/j.outlook.2016.04.007>
8. Menon U, Cohn E, Downs CA, Gephart SM, Redwine L. Precision health research and implementation reviewed through the conNECT framework. *Nurs Outlook.* 2019;67(4):302–310. <https://doi.org/10.1016/j.outlook.2019.05.010>
9. Kwong JC, Khondker A, Kim JK, Chua M, Keefe DT, Santos J, et al. Posterior Urethral Valves Outcomes Prediction (PUVOP): a machine learning tool to predict clinically relevant outcomes in boys with posterior urethral valves. *Pediatric Nephrol.* 2021;1:1–8. <https://doi.org/10.1007/s00467-021-05321-3>
10. Rebêlo VCN, Lemos MPR, Silva EKR, Mesquita LSA, Cabral PUL, Carvalho AFM, et al. Post Covid-19 Syndrome: case study. *Res, Soc Develop.* 2022;11(2):e43811225969. <https://doi.org/10.33448/rsd-v11i2.25969>
11. Pezzi MCS, Stipp MAC, Silva IR, Chagas MC. Development of an instructional prototype for technical procedures performed in a material and sterilization center. *Texto Contexto Enferm.* 2020;29:1–11. <https://doi.org/10.1590/1980-265X-TCE-2019-0047>
12. Pressman RS, Maxim BR. Engenharia de software: uma abordagem profissional. 8° ed. Porto Alegre: AMGH; 2016. 968 P.
13. Acosta AM, Lima MA, Marques GQ, Levandovski PF, Weber LA. Brazilian version of the care transitions measure: translation and validation. *Int Nurs Rev.* 2017;64(3):379-87. <https://doi.org/10.1111/inr.12326>
14. Mello JF, Barbosa SFF. Translation and transcultural adaptation of the Patient Measure of Safety (PMOS) questionnaire to Brazilian Portuguese. *Texto Contexto Enferm.* 2021;30:e20180322. <https://doi.org/10.1590/1980-265X-TCE-2018-0322>
15. Valerio Netto A, Berton L, Takahata AK. Ciência de dados e Inteligência Artificial na Área da Saúde. São Paulo: Editora dos Editores; 2021. 224 p.
16. Collins GS, Reitsma JB, Altman DG, Moons KGM. Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): the TRIPOD Statement. *BMC Med.* 2015;13(1). <https://doi.org/10.1186/s12916-014-0241-z>
17. Shukla S, Maheshwari A, Johri P. Comparative analysis of machine learning algorithms; Stramlit web application. In: 3rd International Conference on Advances in Computing, Communication Control and Networking (ICAC3N) [Internet]. Greater Noida, India. 2021 [cited 2023 Jun 05]. Available from: <https://ieeexplore.ieee.org/document/9725496>
18. Moghadas SM, Vilches TN, Zhang K, Wells CR, Shoukat A, Singer BH. The impact of vaccination on COVID-19 outbreaks in the United States. *medRxiv: Preprint.* 2020. <https://doi.org/10.1101/2020.11.27.20240051>
19. Maltezou HC, Basoulis D, Bonelis K, Gamaletsou MN, Giannouchos TV, Karantoni E, et al. Effectiveness of full (booster) COVID-19 vaccination against severe outcomes and work absenteeism in hospitalized patients with COVID-19 during the Delta and Omicron waves in Greece. 2023;41(14):2343-8. <https://doi.org/10.1016/j.vaccine.2023.01.067>
20. Li W, Wang J, Liu W, Xu C, Li W, Zhang K, et al. Machine Learning Applications for the Prediction of Bone Cement Leakage in Percutaneous Vertebroplasty. *Frontiers Public Health.* 2021;9:812023. <https://doi.org/10.3389/fpubh.2021.812023>