



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO DE CIÊNCIAS DA SAÚDE  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENFERMAGEM

Greici Capellari Fabrizzio

**Enfermagem de Precisão e Inteligência Artificial:** variáveis preditoras e modelos de decisão da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva

Florianópolis  
2023

Greici Capellari Fabrizzio

**Enfermagem de Precisão e Inteligência Artificial:** variáveis preditoras e modelos de decisão da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva

Tese submetida ao Programa de Pós-Graduação em Enfermagem da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Doutora em Enfermagem.

Orientador(a): Profa. Alacoque Lorenzini Erdmann, Dra.

Florianópolis

2023

Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Fabrizzio, Greici Capellari

Enfermagem de Precisão e Inteligência Artificial: :  
variáveis preditoras e modelos de decisão da internação de  
pacientes infectados pela COVID-19 em Unidade de Terapia  
Intensiva / Greici Capellari Fabrizzio ; orientadora,  
Alacoque Lorenzini Erdmann, 2023.

202 p.

Tese (doutorado) - Universidade Federal de Santa  
Catarina, Centro de Ciências da Saúde, Programa de Pós  
Graduação em Enfermagem, Florianópolis, 2023.

Inclui referências.

1. Enfermagem. 2. Informática em Enfermagem. 3.  
Medicina de Precisão. 4. COVID-19. 5. Inteligência  
Artificial. I. Erdmann, Alacoque Lorenzini . II.  
Universidade Federal de Santa Catarina. Programa de Pós  
Graduação em Enfermagem. III. Título.

Greici Capellari Fabrizzio

**Enfermagem de Precisão e Inteligência Artificial: variáveis preditoras e modelos de decisão da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva**

O presente trabalho em nível de Doutorado foi avaliado e aprovado, em 09 de agosto de 2023, pela banca examinadora composta pelos seguintes membros:

Prof. Rodrigo Jensen, Dr.  
Universidade Estadual Paulista

Profa. Diovane Ghignatti da Costa, Dra.  
Universidade Federal de Santa Catarina

Prof. José Luís Guedes dos Santos, Dr.  
Universidade Federal de Santa Catarina

Certificamos que esta é a versão original e final do trabalho de conclusão que foi julgado adequado para obtenção do título de Doutora em Enfermagem

---

Coordenação do Programa de Pós-Graduação

---

Profa. Alacoque Lorenzini Erdmann, Dra.  
Orientadora

Florianópolis, 2023.

Este trabalho é dedicado aos pacientes, aos profissionais de saúde e à ciência. Que ele possa, de alguma forma, amenizar o sofrimento humano em saúde ao facilitar o trabalho dos profissionais de saúde

## **AGRADECIMENTOS**

Ao concluir esta tese tenho a certeza de que não se chega a lugar algum sozinha, são necessárias muitas mãos para viabilizar o trabalho e apoio incondicional dos que nos rodeiam, portanto, tenho muitos a agradecer.

A Lincoln Moura, cientista de dados e programador da pesquisa, por todo o trabalho braçal, afinal “escondido” atrás da inteligência artificial existe muita inteligência e trabalho humano. Você foi incansável e contribuiu para a elevação deste trabalho a outro nível. Para muito além da sua indiscutível competência técnica, pelos nossos momentos diários, por estar ao meu lado desde a comemoração da aprovação no processo seletivo de ingresso ao doutorado até o dia da defesa.

Aos meus pais, Deise e Osmir, e ao meu irmão, Gustavo, pelo apoio e presença na minha vida, também por entenderem os momentos em que foi necessária a minha ausência.

À minha orientadora, professora Dra. Alacoque Lorenzini Erdmann por acreditar e incentivar o desenvolvimento da ideia e viabilizar todos os meios para que a execução da pesquisa fosse possível, sempre muito motivadora e inspiradora.

Ao professor Dr. José Luís Guedes dos Santos, que contribui para a minha formação profissional desde o mestrado. Também atua como coordenador executivo do macroprojeto “Avaliação do cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros” ao qual a tese está vinculada, pela supervisão no estágio de docência e por toda a parceria e compartilhamentos neste período.

Aos colegas do macroprojeto “Avaliação do cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros”, em especial, aos subgrupos 4 e 5 por possibilitarem o desenvolvimento desta pesquisa. Também agradeço aos coletadores, que entraram em contato com os pacientes de abril a dezembro de 2021, o que forneceu dados que subsidiaram as nossas análises.

À Dra. Caroline Cechinel Peiter, que coordenou a coleta de dados, pelas nossas discussões e aprendizados ao longo deste período.

Aos pacientes do estudo que disponibilizaram o seu tempo e viabilizaram a realização desta pesquisa, contribuindo com a construção do conhecimento científico.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e ao Fundo de Apoio à Manutenção e ao Desenvolvimento da Educação Superior (FUMDES) do Estado de Santa Catarina pelo apoio financeiro neste período, os quais

permitiram maior dedicação às atividades da pós-graduação, participação em eventos e cursos de capacitação e pagamento de taxas referente às publicações de artigos científicos.

A Universidade Federal de Santa Catarina que me acolhe desde o mestrado, pela formação pública, gratuita e de qualidade, tenho muito orgulho de fazer desta comunidade.

Ao Programa de Pós-Graduação em Enfermagem por todas as oportunidades de aprendizado em um programa de excelência no país.

A todos os meus professores, cada um de vocês possui uma participação especial na minha formação.

À professora Dra. Gabriela Lanzoni, supervisora do estágio de docência, obrigada por compartilhar seu saber e pela orientação durante os estágios da 8ª fase no Hospital Universitário.

Aos membros da banca examinadora da defesa da tese, a professora Dra. Elisiane Lorensini, Dra. Diovane Ghignatti da Costa, Dra. Patrícia Ilha e aos professores Dr. Rodrigo Jensen e Dr. José Luís Guedes dos Santos pelas significativas contribuições para o aprimoramento deste trabalho.

Aos colegas da pós-graduação, pela convivência, troca de experiências e parceria neste período, vocês tornaram a jornada mais leve.

Aos amigos de caminhada, Paula, Maria Eduarda, Maria Helena, Thiago e Juliana, a presença de vocês foi essencial.

A todos que direta ou indiretamente contribuíram para que este trabalho e esta importante etapa da minha formação profissional fosse possível, o meu muito obrigada!

**O algoritmo da vida.** Se um dia criássemos um algoritmo para nos guiar nas decisões da vida, quantos dados ele precisaria ter para tomar a decisão correta? Os algoritmos de inteligência artificial que vemos surgir todos os dias, para as mais variadas aplicações, se baseiam em dados e, na verdade, são ferramentas matemáticas que, no fundo, analisam probabilidades e padrões. Infelizmente, a vida é mais complexa que isso. As decisões, muitas vezes, não se baseiam em dados ou experiência prévia, mas na percepção que temos do que devemos fazer, com base em poucas informações em geral. A intuição pesa. A emoção, por vezes, vence a razão. Vivemos na tentativa e erro. Se formos zelosos demais, podemos nunca crescer. Se formos ousados demais, podemos nos perder. Porém, se não ousarmos, não evoluímos; se não formos cuidadosos, podemos trilhar um caminho ruim. O balanço entre o zelo e a ousadia, talvez, defina o sucesso. Filosófico, não? O que trago aqui é o conceito de que inteligência humana é heurística: um "atalho mental" para tomarmos decisões com poucas informações, com auxílio da criatividade, da intuição. A computação pode utilizar metodologia heurística para encurtar caminhos. Podemos usar esses recursos em inteligência artificial. Portanto, entenda que diferente dos algoritmos de IA, o da vida é mais suscetível ao erro. E, talvez, essa seja a graça de viver. Enquanto isso, "carpe diem", aproveite o seu dia e vá pavimentando o caminho das decisões (Sacomani, 2022).

## RESUMO

**Objetivo:** Aplicar algoritmos de inteligência artificial para identificação de variáveis preditoras relacionados à Enfermagem de Precisão: biomarcadores clínicos (sinais e sintomas, comorbidades), epigenética (contexto de vida) e fenótipo (hábitos de vida) para predição da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva e, a partir da identificação do melhor modelo, desenvolver um Web App para estimar o risco de internação de pacientes com COVID-19 em Unidade de terapia Intensiva. **Método:** O estudo pautou-se em quatro etapas, com diferentes métodos de pesquisa: 1ª etapa ou revisão integrativa da literatura, buscou conhecer a literatura científica acerca da Enfermagem de Precisão para definição do referencial teórico da pesquisa e resultou na inclusão de 13 publicações; 2ª etapa ou projeto piloto, estudo retrospectivo, realizado de março de 2020 a abril de 2021, por meio das notificações de COVID-19 do município de Florianópolis, a amostra foi composta por 190 pacientes e buscou a validação do método a ser realizado na próxima etapa do estudo, a partir da aplicação e comparação de 08 algoritmos de aprendizado de máquina para identificação das variáveis preditoras e predição da admissão de pacientes internados e contaminados pela COVID-19 em Unidade de Terapia Intensiva; 3ª etapa ou desenvolvimento do modelo preditivo, estudo retrospectivo, multicêntrico, realizado de abril a dezembro de 2021, com uma amostra de 547 pacientes provenientes de cinco hospitais universitários brasileiros para desenvolver um modelo de inteligência artificial, a partir de testes de 08 modelos de aprendizado de máquina, para identificar as variáveis preditoras e prever a admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva. O desempenho dos modelos das etapas 2ª e 3ª foram avaliados por meio da validação cruzada dos dados e das métricas: Área Acima da Curva, sensibilidade e especificidade; 4ª etapa ou produção tecnológica foi o produto final do estudo que resultou no desenvolvimento de um *Web App* via *Streamlit*, desenvolvido no *Python*, para predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva a partir do modelo que apresentou a melhor performance na etapa 3. A pesquisa obteve aprovação do Comitê de Ética em Pesquisa mediante CAAE 38912820.3.1001.0121 e parecer de aprovação número 4.347.463. **Resultados:** A etapa 1 demonstrou que os estudos sobre Enfermagem de Precisão centram-se na identificação de hábitos de vida, genótipo, fenótipo e de biomarcadores e suas relações com desfechos, implantação e testes de cuidados específicos de enfermagem, os quais consideram a condição daquele paciente para prevenção de complicações e voltam-se para a melhoria da qualidade de vida. Na etapa 2, o melhor modelo para predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva foi a rede neural com uma Área Acima da Curva (0.917), sensibilidade (0.861) e especificidade (0.825), tendo como variáveis preditoras de maior influência sobre o modelo: internação hospitalar, raça e dor de garganta. Na etapa 3, a árvore de decisão foi o modelo que apresentou a melhor performance preditiva com uma Área Acima da Curva (0.668), sensibilidade (0.633) e especificidade (0.669), sendo as variáveis preditoras de maior influência sobre o modelo: idade, internação hospitalar na Universidade Federal do Amazonas e número de pessoas residentes no domicílio. Na etapa 4, o *Web App* 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. **Conclusão:** A enfermagem atua diretamente na identificação dos biomarcadores

clínicos por meio da coleta de dados no histórico de enfermagem, exames físicos e laboratoriais. A identificação dos mecanismos subjacentes que estão por trás das doenças e de situações de agravamento dos quadros fornecem informações que auxiliam na tomada de decisão do profissional enfermeiro para planejar e implementar intervenções de precisão. Portanto, ao finalizar este estudo conclui-se que é possível prever a internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva com as variáveis disponíveis, a partir do referencial teórico baseado na Enfermagem de Precisão. No entanto, é necessário levar em consideração a dinamicidade do curso evolutivo da doença e da evolução das formas de combate, em que houve o surgimento de novas variantes, medicamentos passaram a ser indicados para a doença e vacinas foram desenvolvidas, bem como o auxílio tecnológico no combate à pandemia. As novas variantes tiveram como características sintomas diferenciados do começo da pandemia, assim as variáveis que capturamos como subproduto do cuidado rotineiro também mudam, o que pode influir na performance preditiva dos modelos. O presente trabalho resultou na submissão do artigo 2 em um periódico (A4); o mesmo trabalho foi premiado entre os cinco melhores trabalhos do Congresso Brasileiro de Informática em Saúde em 2021. O artigo 4, relacionado a descrição do Web App, foi aceito para publicação na Revista Brasileira de Enfermagem (A4) e foi registrado como programa de computador, denominado COVID-19 UTI PREDICTOR, no Departamento de Inovação da Universidade Federal de Santa Catarina e Instituto Nacional da Propriedade Intelectual (512023002623-9). As autoras também publicaram o editorial intitulado “Enfermería de precisión: una aliada para potenciar la gestión del cuidado” na Revista Avances em Enfermería.

**Palavras-chave:** Informática em Enfermagem; Medicina de Precisão; COVID-19; Inteligência Artificial; Tomada de Decisões.

## ABSTRACT

**Objective:** To apply artificial intelligence algorithms to identify predictor variables related to Precision Nursing: clinical biomarkers (signs and symptoms, comorbidities), epigenetics (life context) and phenotype (lifestyle habits) to predict the admission of patients infected with COVID-19 to an Intensive Care Unit and, based on the identification of the best model, to develop a Web App to estimate the risk of hospitalisation of patients with COVID-19 in an Intensive Care Unit. **Method:** The study was based on four stages, using different research methods: Stage 1, or integrative literature review, sought to understand the scientific literature on Precision Nursing to define the theoretical framework of the research and resulted in the inclusion of 13 publications; 2nd stage or pilot project, retrospective study, carried out from March 2020 to April 2021, through COVID-19 notifications from the municipality of Florianópolis, the sample consisted of 190 patients and sought to validate the method to be carried out in the next stage of the study, based on the application and comparison of 08 machine learning algorithms to identify predictor variables and predict the admission of patients hospitalised and contaminated by COVID-19 in an Intensive Care Unit; 3rd stage or development of the predictive model, a retrospective, multicentre study, carried out from April to December 2021, with a sample of 547 patients from five Brazilian university hospitals to develop an artificial intelligence model, based on tests of 08 machine learning models, to identify predictor variables and predict the admission of patients infected with COVID-19 to the Intensive Care Unit. The performance of the models from stages 2 and 3 was assessed through cross-validation of the data and the metrics: Area Under the Curve, sensitivity and specificity; stage 4 or technological production was the final product of the study which resulted in the development of a Web App via Streamlit, developed in Python, to predict the hospitalisation of patients infected with COVID-19 in an Intensive Care Unit based on the model that showed the best performance in stage 3. The research was approved by the Research Ethics Committee under CAAE 38912820.3.1001.0121 and approval number 4.347.463. **Results:** Stage 1 showed that studies on Precision Nursing focus on the identification of lifestyle habits, genotype, phenotype and biomarkers and their relationship with outcomes, implementation and testing of specific nursing care, which considers the condition of that patient to prevent complications and focus on improving quality of life. In stage 2, the best model for predicting the hospitalisation of patients infected with COVID-19 in the Intensive Care Unit was the neural network with an Area Under the Curve (0.917), sensitivity (0.861) and specificity (0.825), with the most influential predictor variables on the model being hospitalisation, race and sore throat. In stage 3, the decision tree was the model that showed the best predictive performance with an Area Under the Curve (0.668), sensitivity (0.633) and specificity (0.669), with the most influential predictor variables on the model being: age, hospitalisation at the Federal University of Amazonas and number of people living in the household. In stage 4, the Web App stratifies patients admitted to clinical units with a higher probability of being admitted to the Intensive Care Unit, acting as a tool to support decision-making by healthcare professionals. **Conclusion:** Nursing is directly involved in identifying clinical biomarkers by collecting data in the nursing history, physical examinations and laboratory tests. Identifying the underlying mechanisms behind diseases and situations where conditions worsen provides information that helps nurses make decisions to plan and implement precise interventions. Therefore, at the end of this study, it is concluded that it is possible to predict the hospitalisation

of patients infected with COVID-19 in an Intensive Care Unit with the available variables, based on the theoretical framework based on Precision Nursing. However, it is necessary to take into account the dynamic course of the disease and the evolution of ways to combat it, in which new variants have emerged, drugs have been indicated for the disease and vaccines have been developed, as well as technological aid in combating the pandemic. The new variants were characterised by different symptoms from the start of the pandemic, so the variables we capture as a by-product of routine care also change, which can influence the predictive performance of the models. This work resulted in the submission of article 2 in a journal (A4); the same work was awarded among the five best papers at the Brazilian Congress of Health Informatics in 2021. Article 4, related to the description of the Web App, was accepted for publication in the Brazilian Journal of Nursing (A4) and was registered as a computer programme, called COVID-19 UTI PREDICTOR, with the Innovation Department of the Federal University of Santa Catarina and the National Institute of Intellectual Property (512023002623-9). The authors also published an editorial entitled "Precision nursing: an ally to enhance care management" in the journal *Avances en Enfermería*.

**Keywords:** Nursing Informatics; Precision Medicine; COVID-19; Artificial Intelligence; Decision Making.

## LISTA DE FIGURAS

Figura 1 - Infecção por SARS - CoV - 2 nas células humanas.....	29
Figura 2 - Articulação entre as áreas médicas e de enfermagem para um cuidado personalizado. ....	33
Figura 3 - Elementos que fundamentam a Enfermagem de Precisão. ....	35
Figura 4 - Fluxograma de Identificação, Seleção e Inclusão dos Estudos. ....	45
Figura 5 - Relação entre os conceitos de inteligência artificial, aprendizado de máquina e aprendizado profundo.....	58
Figura 6 - Etapas percorridas durante o estudo.....	66
Figura 7 - Etapas do processo de mineração de dados. ....	67
Figura 8 - Exemplos de curva ROC. ....	69
Figura 9 - Fluxograma de seleção de pacientes e mineração dos dados. ....	78
Figura 10 - Pipeline dos dados ....	79
Figura 11 - Representação de dados ausentes.....	80
Figura 12 - Análise de dados realizada no <i>software Orange Data Mining</i> .....	82
Figura 13 - Matriz de correlação bidimensional.....	85
Figura 14 - Característica de Operação do Receptor (ROC) para o modelo de rede neural. ....	88
Figura 15 - Matriz de confusão para o modelo de rede neural. ....	89
Figura 16 - Representação de uma rede neural artificial.....	89
Figura 17 - Apresentação dos valores ausentes no banco de dados em uma escala de cores.....	102
Figura 18 - Apresentação das variáveis após o tratamento de dados sem conter valores ausentes. ....	104
Figura 19- Fluxograma de tratamento dos dados.....	107
Figura 20 - Pacientes não internados e internados em UTI por hospital.....	109
Figura 21 - Número de pessoas residentes no mesmo domicílio não internadas e internadas em UTI.....	110
Figura 22 - Relação entre a variável tabagismo e UTI. ....	110
Figura 23 - Relação entre a variável doença respiratória crônica e UTI.....	111
Figura 24 - Gráfico de correlação entre as variáveis preditoras. ....	112
Figura 25 - Desequilíbrio e equilíbrio entre as classes.....	113
Figura 26 - Variáveis preditoras de maior influência sob o modelo ....	114

Figura 27 - Característica de Operação do Receptor (ROC) para o modelo de árvore de decisão .....	115
Figura 28 - Matriz de confusão para o modelo de árvore de decisão.....	115
Figura 29- Árvore de decisão .....	116
Figura 30 - Matriz de confusão .....	130
Figura 31 - Fluxograma de construção do <i>Web App</i> .....	131
Figura 32 - Página inicial do <i>Web App</i> .....	133
Figura 33 - Exploração visual e interativa do banco de dados no <i>Web App</i> .....	133
Figura 34 - Inserção dos dados clínicos do paciente no <i>Web App</i> .....	135
Figura 35 - Simulação de caso em que o paciente apresenta baixa probabilidade de ir para UTI .....	136
Figura 36 - Simulação de caso em que o paciente apresenta alta probabilidade de ir para UTI .....	136

## LISTA DE QUADROS

Quadro 1 - Estratégia de busca e referências identificadas. ....	43
Quadro 2 - Artigos incluídos na amostra ordenados pelo ano de publicação e nível de evidência. ....	46
Quadro 3 - Estrutura ConNECT para orientação de pesquisas em Enfermagem de Precisão. ....	51
Quadro 4 - Matriz de confusão. ....	70
Quadro 5 - Manuscritos resultantes da pesquisa de acordo com cada etapa do estudo. ....	72
Quadro 6 – Tipo das variáveis do estudo. ....	99
Quadro 7 - Softwares utilizados em cada etapa da pesquisa.....	105

## LISTA DE TABELAS

Tabela 1 - Dados demográficos basais e dados clínicos dos pacientes do estudo no momento de preenchimento da ficha de notificação. ....	83
Tabela 2 - Ranking das variáveis. ....	86
Tabela 3 - Desempenho dos algoritmos. ....	88
Tabela 4 - Apresentação do cálculo amostral e do cálculo amostral para comparação por Hospital Universitário. ....	101
Tabela 5 - Número de participantes da pesquisa por hospital e por questionário. ...	106
Tabela 6 - Exploração descritiva dos dados em relação à internação em UTI. ....	108
Tabela 7 - Desempenho dos algoritmos. ....	114

## LISTA DE ABREVIATURAS E SIGLAS

ANVISA	Agência Nacional de Vigilância Sanitária
AST	Aspartato Aminotransferase
AUC	Área Acima da Curva
CINAHL	<i>Cumulative Index to Nursing and Allied Health Literature</i>
MEDLINE	<i>Medical Literature Analysis and Retrieval System Online</i>
LILACS	Literatura Latino-Americana e do Caribe em Ciências da Saúde
CRISPR	<i>Clustered Regularly Interspaced Short Palindromic Repeats</i>
CTM-15	<i>Care Transitions Measure</i>
DE	Diagnóstico de Enfermagem
DeCS	Descritores em Ciências da Saúde
ECA	Enzima Conversora de Angiotensina
EP	Enfermagem de Precisão
FN	Falso Negativo
FP	Falso Positivo
IA	Inteligência Artificial
IE	Intervenção de Enfermagem
IMC	Índice de Massa Corpórea
INPI	Instituto Nacional da Propriedade Intelectual
KNN	<i>K Nearest Neighbor</i>
LGPD	Lei Geral de Proteção de Dados
MERS-CoV	Síndrome Respiratória do Oriente Médio
MeSH	<i>Medical Subject Headings</i>
ODS	Objetivos do Desenvolvimento Sustentável
OPAS	Organização Pan-Americana de Saúde
PBE	Prática Baseada em Evidência
PCR	Proteína C Reativa
PE	Processo de Enfermagem
PMOS	<i>Patient Measure Of Safety</i>
PNIIS	Política Nacional de Informação e Informática em Saúde
RES	Registros Eletrônicos em Saúde
RIPSA	Rede Interagencial de Informações para a Saúde
RNIS	Rede Nacional de Informações em Saúde

SAMU	Serviço de Atendimento Móvel de Urgência
SARS-CoV	Síndrome Respiratória Aguda Grave
SCIELO	<i>Scientific Eletronic Library Online</i>
SDC	Suporte à Decisão Clínica
SUS	Sistema Único de Saúde
SVM	<i>Support Vector Machine</i>
TICs	Tecnologias da Informação e Comunicação
TRIPOD	Relatório Transparente de um Modelo de Previsão Multivariável para Prognóstico ou Diagnóstico Individual
UTI	Unidade de Terapia Intensiva
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
XGBoost	<i>Multilayer Perceptron, Extreme Gradient Boosting</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>21</b>
<b>2</b>	<b>OBJETIVOS E TESE</b> .....	<b>26</b>
2.1	OBJETIVO GERAL.....	26
2.2	OBJETIVOS ESPECÍFICOS .....	26
2.3	TESE .....	26
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>28</b>
3.1	PATOGÊNESE DA COVID-19 .....	28
3.2	ENFERMAGEM DE PRECISÃO.....	30
3.3	ARTIGO 1 – ENFERMAGEM DE PRECISÃO: REVISÃO INTEGRATIVA DA LITERATURA .....	39
3.4	INICIATIVAS NACIONAIS PARA A SAÚDE DIGITAL E ALINHAMENTO DA PESQUISA A AGENDA NACIONAL E DAS AMÉRICAS .....	55
3.5	INTELIGÊNCIA ARTIFICIAL .....	57
3.6	ÉTICA E INTELIGÊNCIA ARTIFICIAL.....	60
3.7	SISTEMAS COMPLEXOS.....	62
<b>4</b>	<b>MÉTODO</b> .....	<b>65</b>
4.1	ANÁLISE DOS DADOS E MODELAGEM COM INTELIGÊNCIA ARTIFICIAL .....	67
4.2	VALIDADE DO MODELO DE PREDIÇÃO .....	68
4.3	ASPECTOS ÉTICOS.....	71
<b>5</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	<b>72</b>
5.1	ARTIGO 2 – PREDIÇÃO DA INTERNAÇÃO DE PACIENTES INFECTADOS PELA COVID-19 EM UNIDADE DE TERAPIA INTENSIVA NA CIDADE DE FLORIANÓPOLIS/SC.....	72
5.3	ARTIGO 3 – PREDIÇÃO DE ADMISSÕES NA UNIDADE DE TERAPIA INTENSIVA DE PACIENTES COM COVID-19 EM CINCO HOSPITAIS UNIVERSITÁRIOS DO BRASIL .....	93
5.4	ARTIGO 4 – <i>WEB APP</i> PARA PREDIÇÃO DA INTERNAÇÃO EM UNIDADE DE TERAPIA INTENSIVA POR COVID-19 .....	124
<b>6</b>	<b>CONCLUSÃO</b> .....	<b>143</b>
	<b>REFERÊNCIAS</b> .....	<b>150</b>

APÊNDICE A – PROTOCOLO PARA REVISÃO INTEGRATIVA DA LITERATURA.....	159
APÊNDICE B – INSTRUMENTO DE COLETA DE DADOS.....	162
APÊNDICE C - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO.....	166
APÊNDICE D – TRATAMENTO DOS DADOS.....	168
APÊNDICE E – RELATÓRIO DE VISITA TÉCNICA .....	186
ANEXO A - APROVAÇÃO DO COMITÊ DE ÉTICA EM PESQUISA .....	190
ANEXO B – TRABALHO DERIVADO DO ARTIGO 2 APRESENTADO E PUBLICADO NOS ANAIS DO XVIII CONGRESSO BRASILEIRO DE INFORMÁTICA EM SAÚDE EM 2021 .....	198
ANEXO C – PRINT DO E-MAIL DE ACEITE DA REVISTA BRASILEIRA DE ENFERMAGEM DO ARTIGO 4 .....	199
ANEXO D – CERTIFICADO DE REGISTRO DE PROGRAMA DE COMPUTADOR DO <i>WEB ABB</i> DESCRITO NO ARTIGO 4 .....	200
ANEXO E – EDITORIAL SOBRE ENFERMAGEM DE PRECISÃO PUBLICADO PELAS AUTORAS.....	201
ANEXO F – ARTIGO SOBRE INTELIGÊNCIA ARTIFICIAL PUBLICADO PELAS AUTORAS.....	202

## 1 INTRODUÇÃO

No final de 2019 foi descrita uma pneumonia de etiologia desconhecida em Wuhan, na China. Inicialmente, o surto da doença foi relacionado a pacientes que tiveram contato com um mercado de venda de frutos do mar. Em janeiro de 2020 foi isolado pelos pesquisadores o novo coronavírus, Síndrome Respiratória Aguda Grave coronavírus-2 (SARS-CoV-2), também conhecido como 2019-nCoV e mais tarde denominado COVID-19. A família dos coronavírus já havia causado epidemias em 2003, com a Síndrome Respiratória Aguda Grave (SARS-CoV), em 2012, com a Síndrome Respiratória do Oriente Médio (MERS-CoV). Ambas com uma taxa de letalidade de 40% e 10%, respectivamente. O novo coronavírus, embora apresente uma taxa de letalidade que varia em torno de 2%, é mais transmissível que os demais vírus da família (Jiang *et al.*, 2020).

Ao se espalhar rapidamente pelo mundo, a COVID-19 foi então declarada uma pandemia de interesse de saúde pública. O comportamento da doença é variado, desde infecções assintomáticas, doença leve, a casos de doença grave e mortalidade (Paudel *et al.*, 2020; OMS, 2020). Quando sintomática, as principais manifestações clínicas da doença incluem febre (90%), tosse (75%) e dispneia (50%) (Jiang *et al.*, 2020). Entretanto, esses sinais e sintomas podem variar de acordo com o surgimento de novas variantes e alterações na cepa da doença.

A transmissão do SARS-CoV-2 pode ocorrer de mãe para filho (transmissão vertical), via sanguínea, fecal-oral e a principal delas, é a transmissão de contato por gotículas. Na transmissão por gotículas, a saliva do indivíduo infectado entra em contato com nariz e boca de paciente sadio. Assim, a principal medida contra a disseminação é o distanciamento social para interromper a cadeia de transmissão (OMS, 2020; Wilder-Smith; Freedman, 2020).

Para exemplificar com números as dimensões pandêmicas, em 10 de março de 2023 foram 676.609.955 casos clínicos confirmados da doença em todo o mundo e 6.881.955 mortes em todo o mundo. O Brasil posiciona-se como o terceiro país do mundo em número de casos, com 37.085.675 casos da doença e como o segundo país em número de mortes, chegando a 699.310 mortos (Johns Hopkins, 2023).

Em 22 de maio de 2023 no Estado de Santa Catarina foram confirmados 2.021.314 casos da COVID-19 e 22.789 óbitos provocados pela doença (Santa

Catarina, 2023). Enquanto na cidade de Florianópolis na mesma data haviam sido confirmados 213.970 casos e 1.341 óbitos (Florianópolis, 2023).

Em relação a tratamento medicamentoso contra a doença, no Brasil, a Agência Nacional de Vigilância Sanitária (ANVISA) aprovou o uso dos seguintes medicamentos: remdesivir, baricitinibe, molnupiravir, sotrovimabe, paxlovid (nirmatrelvir + ritonavir) e tocilizumabe (ANVISA, 2023).

As vacinas também demonstram o seu potencial imunizante contra o vírus, principalmente a sua atuação na prevenção dos quadros clínicos mais graves da doença. Em 2020 algumas vacinas receberam autorização para uso emergencial em países europeus e nos Estados Unidos. No Brasil, em janeiro de 2021, a ANVISA autorizou o uso emergencial de duas vacinas. Em fevereiro de 2022, houve registro concedido a dois imunizantes, são eles: *comirnaty* (Pfizer/Wytech) e *Oxford/covishield* (Fiocruz e Astrazeneca); uso emergencial de mais dois imunizantes: *coronovac* (Butantan), *Janssen vaccine* (Jansen-Cilag). Em 2023 às 04 vacinas mencionadas anteriormente seguem aprovadas para uso e foi incluída a vacina *comirnaty* bivalente (Pfizer) e autorização para importação excepcional da *sputnik* (Castro, 2021; ANVISA, 2023).

No dia 10 de março de 2023 havia 13.338.833.198 doses de vacina aplicadas em todo o mundo e 502.262.440 doses aplicadas no Brasil. No mês de maio de 2023 o Estado de Santa Catarina havia aplicado 16.857.984 e 508.633 pessoas vacinadas em Florianópolis. Entretanto, o aumento das alternativas de imunização não representa disponibilidade do imunizante e acesso equilibrado a todos os países (Castro, 2021; Johns Hopkins, 2023; Santa Catarina, 2023a; Florianópolis, 2023).

Assim, além das medidas tradicionais, adotadas como estratégias de saúde pública, para contenção da transmissão viral como a higienização das mãos, o distanciamento social e o uso de máscaras, aliadas a imunização em massa da população e o tratamento medicamento, faz se necessário o emprego de outras estratégias para auxiliar no enfrentamento à pandemia. Sobretudo, o desenvolvimento de recursos tecnológicos, que auxilia no enfrentamento de iniquidades relacionadas aos processos de adoecimento e das desigualdades de acesso aos serviços de saúde (Castro, 2021).

Uma série de tecnologias digitais foram desenvolvidas nos últimos anos, as quais, aliadas às medidas de contenção da propagação da COVID-19, podem ser

empregadas para o enfrentamento da pandemia (Ting; Carin; Dzau; Wong, 2020). As técnicas computacionais, Tecnologias da Informação e Comunicação (TICs) e técnicas de Inteligência Artificial (IA) são ferramentas que podem auxiliar na organização e análise de uma grande quantidade de dados sobre a vigilância em saúde, previsões de tendências e recursos de saúde. Essas informações combinadas com modelos matemáticos e inteligência artificial são representativas para o gerenciamento da COVID-19 e outras pandemias (Bragazzi *et al.*, 2020).

A IA é uma área dentro da ciência da computação para desenvolvimento de métodos de análise de dados a partir da reprodução de uma inteligência semelhante à de seres humanos (Shimizu; Nakayama, 2020; Kilic, 2020). É uma ferramenta emergente com potencial para identificação do vírus, monitoramento dos pacientes infectados, criação de modelos que auxiliam na melhor adesão ao tratamento proposto e nas tomadas de decisão. Além disso, por meio da extração de conhecimento a partir da análise de dados, pode-se apontar estratégias de prevenção e controle, rastreamento da doença e desenvolvimento de pesquisa sobre o vírus. Entre outras funcionalidades, como desenvolvimento de medicamentos, vacinas e aplicações moleculares e epidemiológicas (Vaishya *et al.*, 2020).

Dentro da grande área de IA existem subáreas, como o aprendizado de máquina e o aprendizado profundo (Shimizu; Nakayama, 2020). Os modelos gerados a partir de algoritmos de aprendizado de máquina possuem capacidade para aprender as relações entre um conjunto de dados e, a partir disso, auxiliar no estabelecimento de parâmetros clínicos, essas aplicações mostram-se úteis para o desenvolvimento de modelos preditivos (Hou *et al.*, 2021).

Estudos anteriores utilizaram-se de técnicas de inteligência artificial para prever a transferência de pacientes para UTI (Cheng *et al.*, 2020; Covino *et al.*, 2020; Hou *et al.*, 2021). Para predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva e para prever os valores futuros dos sinais vitais por pacientes já internados na terapia intensiva foram criados modelos de aprendizado de máquina com os seguintes algoritmos: *K Nearest Neighbor* (KNN), *Support Vector Machine* (SVM), *Random forest*, *multilayer perceptron*, *extreme gradient boosting* (XGBoost), regressão logística, rede neural, árvore de decisão. O algoritmo *Random forest* foi utilizado em quatro estudos, o XGBoost e o SVM em duas pesquisas (Cheng *et al.*, 2020; Izquierdo; Ancochea; Soriano, 2020; Amer *et al.*, 2021; Magunia *et al.*,

2021; Aznar-Gimeno *et al.*, 2021; Hou *et al.*, 2021). A utilização desses modelos apresenta potencial para serem utilizadas em um contexto de gestão de leitos de UTI (Heidari *et al.*, 2022).

Nesse sentido, por conta do desenvolvimento de recursos tecnológicos em saúde que auxiliam no combate à pandemia, os enfermeiros passaram a atuar em espaços ainda pouco explorados pela profissão, tais como: teleatendimentos, monitoramento remoto de pacientes, os quais contribuem para a gerência do cuidado. A gerência do cuidado compreende a articulação entre as esferas assistencial e gerencial do cuidado, por meio de competências e ferramentas que contribuem para um cuidado qualificado, seguro e, sobretudo, preciso aos pacientes (Bitencourt *et al.*, 2020; Soder *et al.*, 2020).

Diante de um cenário de pandemia, assim como havia acontecido anteriormente em contextos semelhantes, a Enfermagem atuou como protagonista no combate ao vírus e a profissão ganhou destaque em nível internacional. A atuação da Enfermagem ocorreu em diferentes frentes, na coordenação e gerenciamento de serviços e sistemas de saúde, seja para prestar assistência direta (beira leito) aos pacientes ou viabilizar as condições necessárias para o cuidado. Dentre as funções exercidas para a mitigação da transmissão viral incluiu-se a formação de comissões para o planejamento das ações, a organização de fluxos de cuidado e construção de protocolos assistenciais, a capacitação e gestão de recursos humanos, a mobilização de recursos físicos, a atuação beira-leito e na campanha de vacinação contra a doença. Toda essa reorganização dos serviços de saúde para atender as demandas trazidas pela COVID-19, reforçam a necessidade de apoio das TICs e IA (Bitencourt *et al.*, 2020; Soder *et al.*, 2020).

Também exige dos enfermeiros competências digitais, em que, a partir da compreensão de determinada ferramenta que auxilia na assistência obtém-se uma melhora no cuidado prestado e, nas atividades de gestão. Além disso, foi exigido dos enfermeiros competências voltadas para uma leitura da realidade, considerando os aspectos sociais complexos da pandemia, em que se observa o processo de saúde e doença e a demanda por intervenções de Enfermagem (Souza, 2020; Padrini-Andrade *et al.*, 2021).

Nesse sentido, uma área relativamente nova que vem ganhando cada vez mais notoriedade na profissão é a Enfermagem de Precisão (EP), a qual, fundamenta

o cuidado de enfermagem a partir de características e necessidades únicas de uma paciente, como sinais e sintomas, exames clínicos e laboratoriais, patologias de base, as quais, fornecem informações e auxiliam o enfermeiro na tomada de decisão. Também, pode utilizar-se de ferramentas de *E-health*, como o prontuário eletrônico dos pacientes, aplicativos para smartphones e equipamentos vestíveis (relógios/pulseiras/braceletes inteligentes, óculos) para ter acesso a um enorme banco de dados sobre aquele indivíduo (Yuan, 2015; Corwin; Ferranti, 2016).

Estudos anteriores sobre Enfermagem de Precisão identificaram padrões de sintomas vivenciados durante a pré-eclâmpsia na gestação e mais tarde associaram a genótipos. Assim, foi possível identificar padrões que podem influenciar a qualidade de vida na gravidez e o crescimento e desenvolvimento infantil, a saúde materno-fetal e a função familiar (Founds *et al.*, 2018). Considerando todos esses aspectos, o contexto de uma doença infecto contagiosa que atinge toda a humanidade e a atuação próxima da enfermagem prestando assistência à saúde, tendo como aliada técnicas de Inteligência Artificial, este estudo traz os seguintes questionamentos:

- Qual é o atual estado da arte sobre Enfermagem de Precisão?
- Quais são as variáveis preditoras da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva segundo os fundamentos teóricos da Enfermagem de Precisão?
- Qual é o modelo de inteligência artificial que apresenta a melhor performance para predição da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva?

## 2 OBJETIVOS E TESE

Para responder às questões de pesquisa, este estudo reuniu o seguinte objetivo geral e objetivos específicos:

### 2.1 OBJETIVO GERAL

Aplicar algoritmos de inteligência artificial para identificação de variáveis preditoras relacionados à Enfermagem de Precisão: biomarcadores clínicos (sinais e sintomas, comorbidades), epigenética (contexto de vida) e fenótipo (hábitos de vida) para predição da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva e, a partir da identificação do melhor modelo, desenvolver um Web App para estimar o risco de internação de pacientes com COVID-19 em Unidade de terapia Intensiva.

### 2.2 OBJETIVOS ESPECÍFICOS

- ✓ Analisar a produção científica acerca da Enfermagem de Precisão.
- ✓ Identificar variáveis preditoras, aplicar e comparar algoritmos de aprendizado de máquina para predição da admissão de pacientes internados e contaminados pela COVID-19 em Unidade de Terapia Intensiva na cidade de Florianópolis/SC, a partir do referencial teórico da Enfermagem de Precisão.
- ✓ Identificar variáveis preditoras e desenvolver um modelo de inteligência artificial para prever a admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, a partir do referencial teórico da Enfermagem de Precisão, em cinco hospitais universitários brasileiros que foram referência para o atendimento.
- ✓ Desenvolver um *Web App* a partir do modelo com a melhor performance preditiva para estimar o risco de internação de pacientes com COVID-19 em UTI.

### 2.3 TESE

No estudo desta problemática, apresenta-se a seguinte tese:

É possível prever o desfecho de internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, aplicando algoritmos de inteligência artificial que analisam a complexidade das relações e interações das variáveis preditoras disponíveis, fundamentadas no referencial teórico da Enfermagem de Precisão e contribuir para a gestão do cuidado de enfermagem, fornecendo suporte a tomada de decisão e contribuindo para um cuidado mais preciso.

### 3 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, apresenta-se a fundamentação teórica do estudo, a qual fornece aporte literário sobre a temática em voga, apontando, por meio do estado da arte, os conceitos, avanços e lacunas na área de conhecimento. Para tanto, realizou-se uma revisão integrativa da literatura sobre Enfermagem de Precisão e foram descritos achados da literatura sobre os demais tópicos, os quais sustentam o objeto de pesquisa.

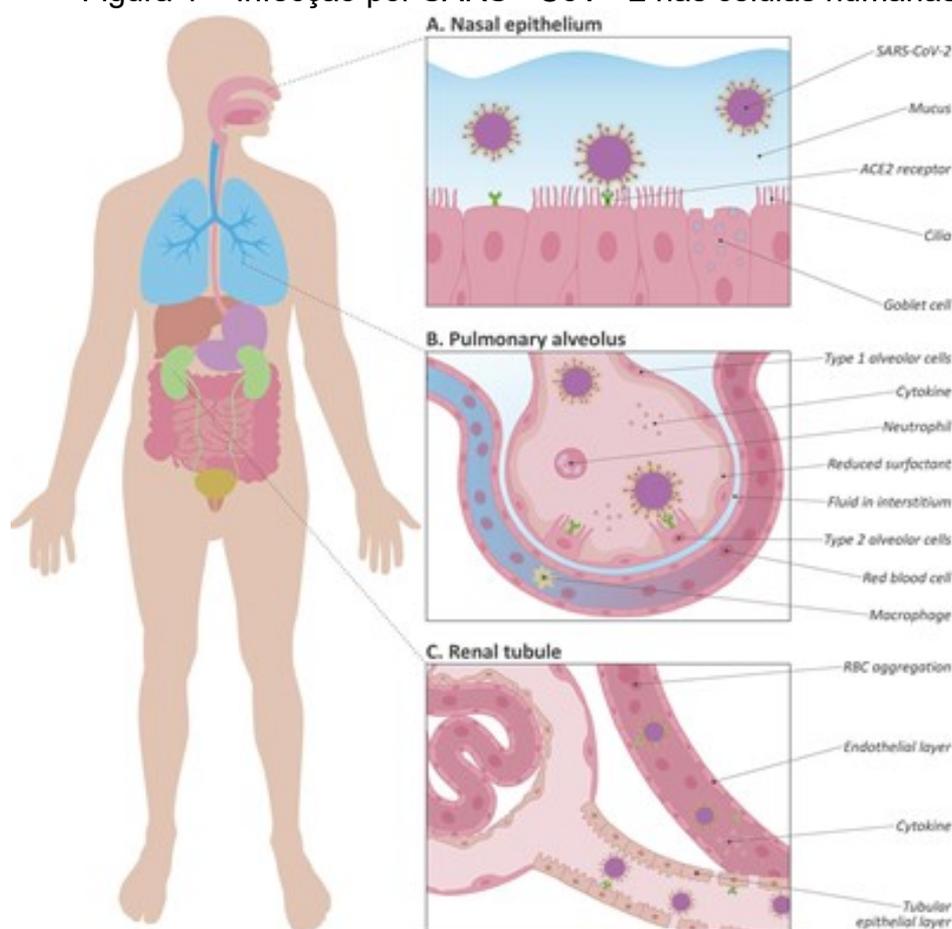
Desta forma a fundamentação teórica é composta pelos seguintes tópicos: 1) Patogênese da COVID-19; 2) Enfermagem de Precisão; 3) Artigo 1 – Enfermagem de Precisão: Revisão integrativa da literatura; 4) Iniciativas nacionais e internacionais de governo digital; 5) Inteligência Artificial; 6) Ética e Inteligência Artificial e 7) Sistemas complexos.

#### 3.1 PATOGÊNESE DA COVID-19

A COVID-19 é uma doença sistêmica, as células virais disseminam-se pelas células humanas pelo sangue e podem afetar, além dos pulmões, vários sistemas, como o trato gastrointestinal, os rins, o fígado, o sistema nervoso, o baço e os músculos. O que pode estar relacionado à Enzima Conversora de Angiotensina (ECA) 2 em nível local (Bourgonje *et al.*, 2020; Machhi *et al.*, 2020).

A ECA 2 é o receptor do SARS-CoV-2 no organismo humano, o vírus possui uma afinidade de ligação aumentada com esse receptor, entre 10 e 20 vezes, por este motivo, é considerado mais patogênico. Conforme ilustrado na Figura 1, a proteína spike viral (S) ultrapassa as membranas mucosas para se ligar ao receptor no trato respiratório superior. Após a infecção das células epiteliais respiratórias, ocorre dano alveolar difuso nos pulmões, hiperplasia reativa difusa de pneumócitos do tipo II, edema bilateral, espessamento dos septos alveolares e infiltração de células inflamatórias (B). A infecção também provoca danos a outros órgãos, como por exemplo, nos rins, ocasiona lesão tubular difusa, dano endotelial dos capilares, o que leva a oclusão da luz do capilar (C) (Bourgonje *et al.*, 2020).

Figura 1 – Infecção por SARS - CoV - 2 nas células humanas.



Fonte: Bourgonje *et al.* (2020).

A doença apresenta algumas alterações de biomarcadores laboratoriais bastante características a que se deve atentar, como: leucopenia, linfopenia, elevação da aspartato aminotransferase (AST), proteína C reativa (PCR), dímero D, hipersensibilidade-troponina I (Lake, 2020). Existe uma grande quantidade de marcadores afetados pela infecção da COVID-19 quando se refere a cuidados em saúde.

Entretanto, ainda não foram estabelecidos padrões de biomarcadores para estimar o prognóstico de pacientes, o que dificulta a alocação de recursos humanos, materiais, entre outros. Também não está descrito na literatura científica se as comorbidades são variáveis que apresentam maior influência na mortalidade ou para necessidade de cuidados intensivos, quando comparadas a variáveis clínicas, como biomarcadores e fenótipo (Hou *et al.*, 2021).

Outro fator a ser considerado são as apresentações heterogêneas da doença, alguns pacientes apresentam infecções leves ou assintomáticas, enquanto outros desenvolvem a forma grave, podendo chegar à falência múltipla de órgãos (Hou *et al.*, 2021). Estas situações incitam questionamentos e abrem precedentes para pesquisas de identificação de biomarcadores e sinais e sintomas que influenciam na gestão do atendimento aos pacientes infectados pela COVID-19.

Além disso, outros questionamentos surgem quanto ao curso evolutivo da doença, ainda não se entende exatamente como acontece a imunidade, por quanto tempo ela permanece e a possibilidade de reinfeção por indivíduos já recuperados. As mutações do SARS-CoV-2 também estão em debate, uma vez que influenciam na propagação do vírus e no potencial de proteção das vacinas (Santos, 2021).

Portanto, a patogênese da COVID-19 e como será o curso natural da doença ainda desafia a população, as instituições e órgãos da saúde, os pesquisadores do assunto e os profissionais da saúde. É imprescindível que a enfermagem, como profissão intimamente relacionada ao cuidado destes pacientes, participe das discussões e vá em busca de respostas, pautada em referenciais teóricos que embasam a sua atuação e estratégias que favoreçam a gestão do cuidado ao paciente e à família.

O próximo tópico deste trabalho descreve o conceito de Enfermagem de Precisão, um dos referenciais teóricos do estudo, e como ele pode ser aplicado em um contexto de cuidados de enfermagem ao paciente infectado pela COVID-19.

### 3.2 ENFERMAGEM DE PRECISÃO

Antes de adentrar na temática propriamente dita da Enfermagem de Precisão, é preciso abordar a área em seu formato global, que abrange a Saúde de Precisão, uma vez que a Enfermagem de Precisão deriva da saúde de precisão.

Para o neurologista Pedro Schestatsky (2020) em seu livro “Medicina do amanhã” a precisão na área da saúde leva em consideração as particularidades de cada indivíduo e é composta por 5 Ps: Preditiva, Preventiva, Proativa, Personalizada e Parceira. A Predição baseia-se na identificação do risco de desenvolvimento de determinadas condições de saúde ou de agravamento de quadros já instalados e, a partir disso, implementar intervenções mais eficazes.

A Prevenção pode acontecer em vários níveis. Na prevenção primária, não existe um problema de saúde instalado e o objetivo é evitar que ele ocorra, por meio da prática regular de exercícios físicos, vacinação, alimentação saudável, manejo do estresse, entre outros. Na prevenção secundária busca-se a identificação precoce de algum problema de saúde como exames clínicos, laboratoriais e de imagem. A prevenção terciária volta-se para evitar o agravamento de quadros já instalados, por exemplo, controle da diabetes em pacientes acometidos pela doença (Schestatsky, 2020).

A Proatividade posiciona o indivíduo no centro do cuidado da sua saúde, como protagonista das suas ações, portanto, com a possibilidade de inserir mudanças em seu estilo de vida que irão evitar ou postergar doenças. Nesse sentido, alguns monitores instalados em relógios inteligentes e celulares podem auxiliar no monitoramento da glicose, da frequência e traçado cardíaco, do número diário de passos, quanto à qualidade do sono e os níveis de estresse. Os pacientes também possuem acesso a dispositivos digitais, onde acessam informações sobre sua saúde, sobre a sua patologia e formas de tratamento, o que contribui para o entendimento da doença, proatividade no cuidado e tomada de decisão em conjunto com os profissionais de saúde (Schestatsky, 2020).

A Personalização parte do princípio de que cada indivíduo é único, portanto, deve ser cuidado de acordo com as suas características. O surgimento do Big Data possibilitou o armazenamento e processamento de uma grande quantidade de dados sobre um indivíduo, como o sequenciamento do genoma e do microbioma intestinal, a partir da integração e interpretação desses dados extrair informações que podem ser usadas para guiar o paciente em suas decisões de saúde (Schestatsky, 2020).

A Parceria surge da compreensão de que o profissional de saúde é um aliado do paciente, ambos possuem acesso à informação e dados do paciente, no entanto, os profissionais de saúde têm a função de curador de dados, ou seja, interpretar o significado desses dados para auxiliar o paciente a tomar melhores decisões, levando em consideração as preferências, valores e necessidades individuais (Schestatsky, 2020).

Assim, a Saúde de Precisão pode ser definida como a associação de informações do paciente que variam desde a sua formação genética, perpassando por hábitos de vida, bem como o contexto ao qual está inserido e a influência social,

econômica e cultural sobre a sua saúde. Essas informações fornecem elementos que norteiam o cuidado direcionado e específico para aquele indivíduo, com vistas a alcançar o bem-estar em saúde por meio da prevenção de doenças, otimização de diagnóstico e tratamento direcionado (Fu *et al.*, 2020).

Em outras palavras, a Saúde de Precisão utiliza-se de estratégias inovadoras para a prevenção e o tratamento de doenças direcionadas àquele indivíduo. Para tanto, vai além da precisão na identificação de riscos genéticos e na prescrição de terapias de cuidado e terapêuticas, ao incorporar conhecimento sobre a complexidade das interações que interferem na saúde de pacientes e seus familiares (Menon *et al.*, 2019).

Acredita-se que o conceito subjacente de Saúde de Precisão surge em 1907 com o procedimento de transfusão sanguínea. Para que o procedimento se concretize, é necessário a identificação da tipagem sanguínea de um provável doador e do paciente receptor, quando compatíveis, a transfusão é viável. Nesta situação já buscava-se adequar as intervenções necessárias aos cuidados daquele indivíduo de acordo com as suas características. Todavia, os avanços na Saúde de Precisão estão em constante avanço. O sequenciamento do primeiro genoma humano, em 2001, depois de mais de uma década de estudos e a um custo de US \$ 3 bilhões, contribui para um cuidado personalizado e torna a precisão da saúde uma realidade clínica (Hodson, 2016).

No entanto, a temática recebeu maior atenção e ganhou amplitude quando Barack Obama, presidente dos Estados Unidos na época, lançou em 2015 uma pesquisa de coorte longitudinal intitulada “*All of Us*”. O estudo pretende acompanhar variáveis genéticas, ambientais, psicossociais e demográficas de um milhão de participantes de diferentes comunidades e etnias dos Estados Unidos por 10 anos. Estudos semelhantes a este também estão sendo desenvolvidos em países como o Reino Unido, França, Índia e China (Fu *et al.*, 2020).

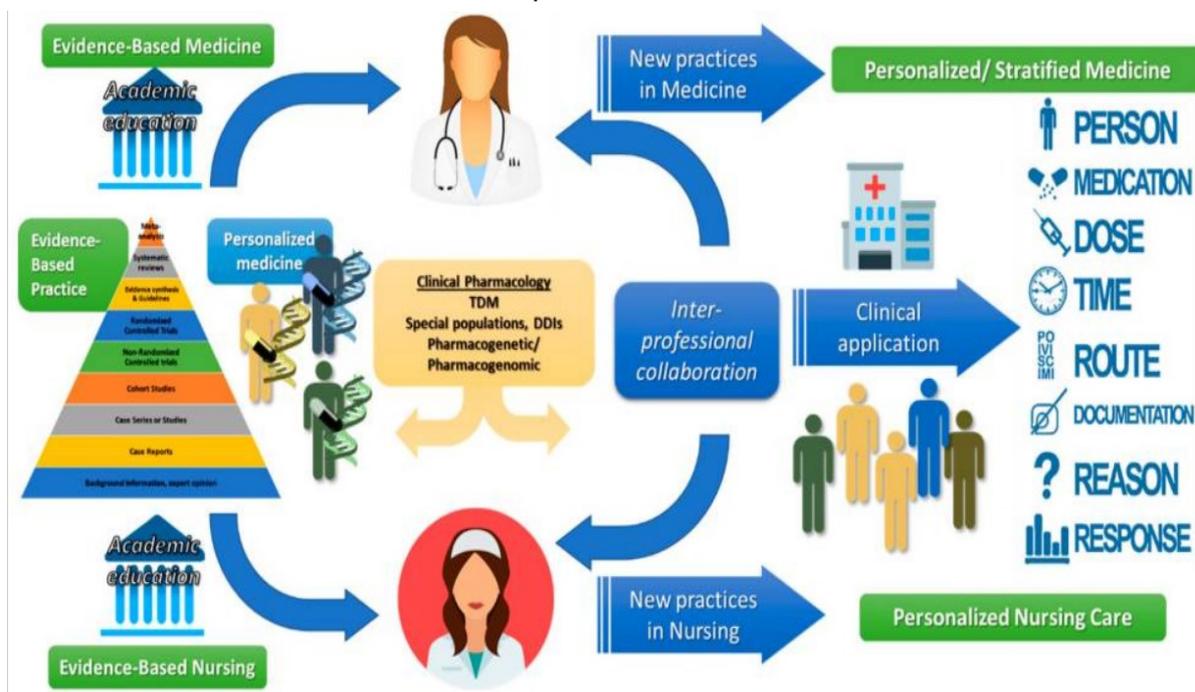
No Brasil, houve o lançamento do Programa Genomas, em 2020. O projeto objetiva sequenciar 100 mil genomas de brasileiros atendidos no Sistema Único de Saúde (SUS) portadores de doenças raras, infectocontagiosas, cardíacas e cânceres. A análise desse banco de dados busca identificar a relação entre os genes dos brasileiros e as suas doenças de base para propor estratégias inovadoras de prevenção, diagnóstico e terapias. O programa contribui para o desenvolvimento

científico e tecnológico em genômica e Saúde de Precisão do Brasil e faz com que o país entre na rota dos estudos sobre precisão (Brasil, 2020).

A saúde deve ser discutida em seu contexto mais amplo, em que se considere as complexas interações entre os fatores biológico, de estilo de vida e ambientais em um cenário de iniquidades em saúde enraizadas em nossa sociedade (Menon *et al.*, 2019). Para tanto, a discussão deve incluir, além dos fatores mencionados anteriormente, o cuidado multiprofissional sobre o ser humano, uma vez que, os diversos saberes contribuem para um cuidado integral do ser humano. Por esse motivo faz-se importante a ampliação do conceito de Saúde de Precisão, para que as diferentes profissões da área da saúde possam se apropriar desse conceito e traduzi-lo para a sua área de conhecimento.

A Figura 2, dos autores Spanakis, Patelarou e Patelarou (2020) demonstra justamente a articulação entre o cuidado personalizado e a sua relação interprofissional nas áreas da enfermagem e medicina, que convergem para novas aplicações clínicas na área de conhecimento, fundamentadas na Prática Baseada em Evidência (PBE).

Figura 2 - Articulação entre as áreas médicas e de enfermagem para um cuidado personalizado.



Fonte: Spanakis; Patelarou; Patelarou (2020).

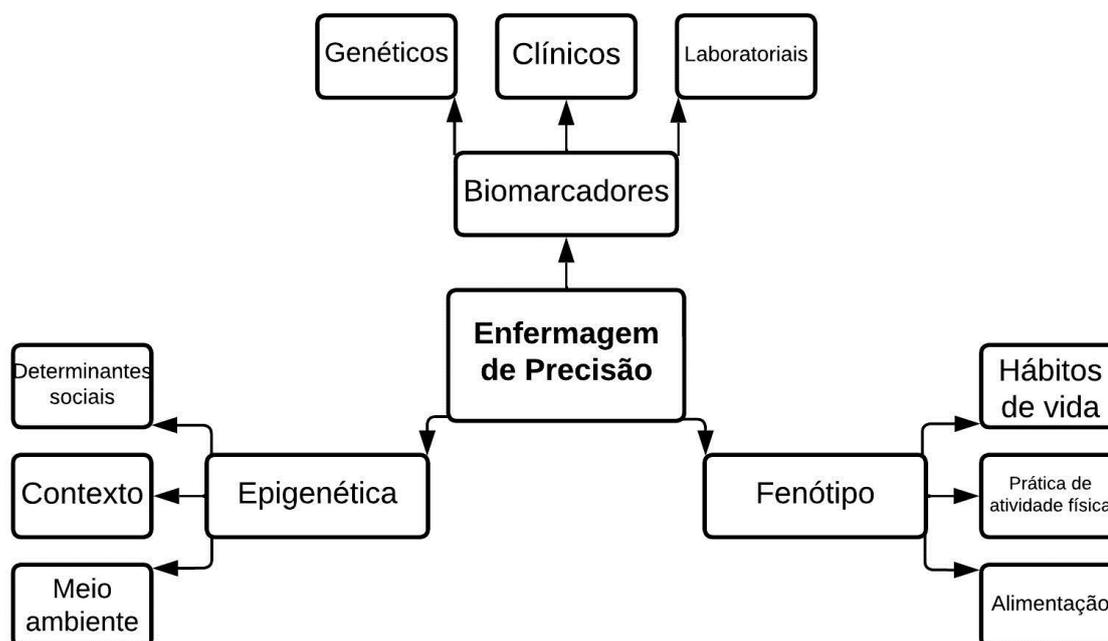
A Enfermagem de Precisão é um ramo da saúde de precisão, e pode ser definida como o cuidado de enfermagem centrado nas necessidades do paciente, ressaltando que estas necessidades são diferentes para cada indivíduo (Yuan, 2015). Comumente a atuação da enfermagem é pautada em cuidados individualizados e personalizados por meio do Processo de Enfermagem (PE), dos quais derivam os Diagnóstico de Enfermagem (DE) e Intervenções de Enfermagem (IE). A Enfermagem de Precisão engloba estes conceitos e busca justamente a associação de dados mensuráveis e preferências do paciente para a sua atuação. Neste cenário, o paciente é inserido na tomada de decisões relacionadas a sua saúde, em que profissionais e pacientes pactuam cuidados pautados em informações concretas.

Para tanto, é premente que a enfermagem melhore sua capacidade de coleta, processamento e análise de dados, utilizando das informações de maneira científica e sem infringir os preceitos da privacidade dos dados. Além disso, pode utilizar-se de tecnologias como equipamentos vestíveis e aplicativos de smartphone para o fornecimento de um guia prospectivo para atuação dos enfermeiros clínicos (Yuan, 2015).

A Enfermagem de Precisão reúne informações para identificar antecipadamente as características de um paciente que responde melhor a determinada intervenção, ou verificar quando uma intervenção não é a mais adequada para ele. Isto é possível pelo teste e adaptação de biomarcadores a intervenções de enfermagem. Por exemplo, ao iniciar os cuidados é identificado que uma mulher não apresenta níveis de cortisol elevados, portanto, uma intervenção para a redução do estresse não irá beneficiá-la, enquanto outra intervenção pode ser mais benéfica (Corwin; Ferranti, 2016). Ou seja, os resultados de pesquisas de Enfermagem de Precisão apresentam melhores resultados quando considerados vários fatores que influenciam a saúde, como biomarcadores, fenótipo, ambiente e determinantes sociais (Menon *et al.*, 2019).

A Figura 3 apresenta uma representação esquemática dos elementos que fundamentam a Enfermagem de Precisão. Observa-se que o conceito é estruturado em um tripé e compreende, para além de biomarcadores clínicos e genéticos, os hábitos de vida e o contexto em que o paciente está inserido.

Figura 3 - Elementos que fundamentam a Enfermagem de Precisão.



Fonte: Elaborado pela autora (2023).

A atuação da Enfermagem centra-se na prestação de cuidados/intervenções que visam atender as necessidades de cuidado do paciente. Dentre um amplo rol de atribuições dos enfermeiros, compete a prescrição de cuidados de enfermagem aos pacientes. Assim, para além dos dados subjetivos considerados para a prescrição de enfermagem, como: sintomas e autorrelato dos pacientes, a integração de biomarcadores constitui-se como uma ferramenta que direciona cuidados mais assertivos em enfermagem. Os biomarcadores são informações mensuráveis objetivamente, como: proteína C reativa, glicose, colesterol, frequência cardíaca, temperatura corporal, entre outros (Corwin; Ferranti, 2016).

Por muito tempo, os pesquisadores de enfermagem centram seus estudos principalmente na ciência dos sintomas e no autogerenciamento, com pesquisas voltadas para intervenções personalizadas e direcionadas para o cuidado centrado no paciente. E esta atuação contribui para a contextualização da compreensão de saúde. Porém, a ampliação da cartela de cuidados centrados na Enfermagem de Precisão é significativa para o direcionamento de intervenções de enfermagem, bem como para o desenvolvimento do cuidado, em todo o processo de cuidados de saúde (Hickey *et al.*, 2019; Menon *et al.*, 2019).

A identificação de sinais, sintomas e 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. Assim, aumentam a probabilidade de utilizar-se de estratégias de prevenção de saúde. A associação de biomarcadores aos sintomas, possibilita a identificação de alterações na homeostase do organismo, para a partir destes riscos, desenvolver e avaliar intervenções individualizadas na melhoria da saúde do paciente e das futuras gerações. A escolha de biomarcadores deve ocorrer de modo a apresentar uma ampla avaliação da condição de base do indivíduo; um biomarcador também deve estar associado a hipóteses de intervenções de Enfermagem de Precisão voltadas para o indivíduo; possibilitando a avaliação da intervenção por meio do monitoramento de sintomas e de forma objetiva pelo monitoramento dos biomarcadores e; por fim, apoiar ou refutar a hipótese que levou à intervenção, baseada em evidências (Corwin; Ferranti, 2016).

A Enfermagem atua muito próximo ao paciente e seus familiares, por este motivo pode aplicar a saúde de precisão para a tomada de decisão compartilhada com o paciente, bem como para o monitoramento e gerenciamento dos sintomas, para decisão de tratamento e avaliação da sua eficácia. Assim, esses dados serão utilizados para acompanhar a evolução clínica da doença, além de decisões sobre a eficácia terapêutica (Fu *et al.*, 2020).

A Enfermagem de Precisão engloba conceitos de igualdade na saúde e preocupa-se com a justiça social, justamente pela compreensão da influência do contexto sobre a saúde (Menon *et al.*, 2019). Assim, também pode-se associar ao conceito de equidade, uma vez que busca um acesso de saúde para todos, a partir do reconhecimento das iniquidades em saúde.

A Enfermagem de Precisão vem justamente com o intuito de aniquilar desigualdades e não de acentuá-las. Todavia, alguns pontos devem ser levados em consideração para evitar a exacerbação das disparidades em saúde. Assim, essa ciência construída de modo proativo apresenta-se como uma ferramenta de promoção da igualdade em saúde e reafirmação do seu compromisso com a justiça social. Por outro lado, se esse conhecimento avançar sem premeditação e planejamento corre um grande risco de acentuar ainda mais as desigualdades em saúde (Menon *et al.*, 2019).

A Enfermagem de Precisão no Brasil, como toda nova ciência, ainda precisa enfrentar alguns empasses para se desenvolver. Inicialmente os pesquisadores de enfermagem precisam de ferramentas que os auxiliem na coleta de dados em saúde e posteriormente na capacidade de análise de dados, já que estamos falando do encontro clínico de uma grande quantidade de dados que inviabiliza análises humanas (Yuan, 2015). Outro ponto a ser levado em consideração, é a capacitação de enfermeiros em genética para assim alavancar o avanço no conhecimento dos genes.

Além dos desafios acima mencionados pode-se associar a padronização de informações em Registros Eletrônicos em Saúde (RES) e a interoperabilidade entre os sistemas de saúde. Esses softwares existem, captam dados, geram informações, mas não possuem a capacidade de troca (interoperabilidade funcional) e uso de dados (interoperabilidade semântica). E a interoperabilidade é a base para aplicações de inteligência artificial e Enfermagem de Precisão.

Por outro lado, os resultados gerados a partir desses estudos e de uma análise criteriosa dos dados conferem a cientificidade necessária para o cuidar em enfermagem (Yuan, 2015). A Enfermagem de Precisão abre precedentes para uma nova era do cuidar em enfermagem.

Por meio da Enfermagem de Precisão é possível uma melhor compreensão dos fatores de proteção de doenças, também possibilita uma melhor compreensão do papel da epigenética e, uma medida quantitativa dos hábitos de vida (Menon *et al.*, 2019). Outra contribuição da Enfermagem de Precisão refere-se à otimização do Suporte de Decisão Clínica (SDC). O SDC significa a apresentação de conhecimento de relevância no momento adequado daquela tomada de decisão, ou seja, reúne e processa dados que são apresentados no ponto exato do fluxo de trabalho para melhoria do cuidado prestado. O SDC apresenta-se como uma ferramenta de alcance da saúde de precisão já proposta em diferentes âmbitos, como: na melhoria da qualidade dos atendimentos, no diagnóstico de câncer de mama e direcionamento de tratamento, nos cuidados intensivos e nos cuidados com a diabetes. Na enfermagem, os estudos sobre SDC ainda estão em fases iniciais, mas acredita-se que auxiliam os enfermeiros no diagnóstico situacional, na prestação de cuidados recomendados pelas diretrizes e na melhoria de processos (Menon *et al.*, 2019).

Diante desse contexto, a tecnologia surge como uma grande aliada na identificação dos pacientes mais adequados para receber o tratamento de precisão.

Por exemplo, por meio de técnicas de correspondência é possível encontrar grupos de pacientes semelhantes e por meio de ferramentas aplicar critérios para identificação de pacientes que melhor se ajustam à "orientação de precisão" (Menon *et al.*, 2019).

Portanto, a Enfermagem de Precisão engloba quatro pontos principais seguindo a linha evolutiva de cuidados em saúde, a saber: prevenção, diagnóstico, tratamento/intervenção e mais recentemente na reabilitação. No âmbito da prevenção, busca a identificação de genes potenciais para o desenvolvimento de doenças, por exemplo, Alzheimer e câncer. A partir desta identificação, o mapeamento dos hábitos de vida daquele indivíduo, ou seja, uma investigação acerca dos seus costumes alimentares, uso de álcool e nicotina, prática de atividade física e contexto ao qual está inserido, como: condições de moradia, lazer, trabalho, transporte. Esses fatores podem influenciar na potencialização ou neutralização de um gene "doente". Ainda em relação à prevenção, a Enfermagem de Precisão pode auxiliar no desenvolvimento de modelos de predição de doenças, também na predição de necessidade de utilização de instituições em saúde, o que fornece informações para a tomada de decisão de profissionais e gestores para mobilização de recursos humanos e materiais. No diagnóstico, observa-se aplicações principalmente em imagens médicas, como a identificação de padrões em raio x de pacientes com COVID-19. Em relação ao tratamento, observa-se a preocupação com uma dose precisa de medicamentos e adaptada às necessidades farmacocinéticas e farmacogenéticas do indivíduo. Também se observa um aumento de intervenções por meio de cirurgia robótica. E a reabilitação é uma área ainda pouco explorada sobre a Enfermagem de Precisão.

### 3.3 ARTIGO 1 – ENFERMAGEM DE PRECISÃO: REVISÃO INTEGRATIVA DA LITERATURA

De acordo com a Instrução Normativa 02/PEN/2021 um dos artigos da tese poderá ser uma revisão de literatura, inserida em capítulo específico, após a introdução. Por este motivo, o artigo 1 da tese faz parte da fundamentação teórica da pesquisa e também é descrito como uma das etapas da pesquisa.

#### **Enfermagem de Precisão: Revisão Integrativa da Literatura**

#### **Precision Nursing Integrative Literature Review**

#### **Revisión Bibliográfica Integradora de la Enfermería de Precisión**

#### **RESUMO**

**Objetivo:** Analisar a produção científica acerca da Enfermagem de Precisão. **Método:** Revisão integrativa da literatura realizada no mês de janeiro de 2021, em 8 bases de dados: SCOPUS, CINAHL, PubMed/MEDLINE, COCHRANE, *Web of Science*, EMBASE, LILACS/BDENF e SciELO, identificando 13 publicações que atenderam aos critérios de inclusão. A revisão integrativa atendeu as recomendações previstas no *PRISMA Statement*. **Resultados:** Os estudos centram-se na identificação de hábitos de vida, genótipo, fenótipo e de biomarcadores, como: glicemia, lipídios, creatinina e índice de massa corpórea e suas relações com desfechos, implantação e testes de cuidados específicos de enfermagem, os quais consideram a condição daquele paciente para prevenção de complicações e voltam-se para a melhoria da qualidade de vida. Também foi mencionada a importância da utilização de ferramentas que auxiliam os pesquisadores na aplicação dos fundamentos de Enfermagem de Precisão como: banco de dados, ferramentas para análise de dados, e outras. **Conclusão:** As produções encontradas na literatura científica sobre Enfermagem de Precisão versam essencialmente sobre a prática clínica em enfermagem, em maior número, e a pesquisa em enfermagem.

**Palavras-chave:** Enfermagem de Precisão; Medicina de Precisão; Assistência Individualizada de Saúde; Variação Biológica Individual; Individualidade; Registros de Saúde Pessoal.

#### **ABSTRACT**

**Objective:** To analyze the scientific production about precision nursing. **Method:** Integrative literature review conducted in January 2021, in 8 databases: SCOPUS, CINAHL, PubMed/MEDLINE, COCHRANE, *Web of Science*, EMBASE, LILACS/BDENF and SciELO, identifying 13 publications that met the inclusion criteria.

The integrative review met the recommendations provided in the PRISMA Statement. **Results:** The studies focus on the identification of lifestyle habits, genotype, phenotype and biomarkers, such as: blood glucose, lipids, creatinine and body mass index and their relationships with outcomes, implementation and tests of specific nursing care, which considered the condition of that patient for prevention of complications and are aimed at improving quality of life. Also mentioned was the importance of using tools that assist researchers in applying the fundamentals of precision nursing such as: databases, data analysis tools, and others. **Conclusion:** The productions found in the scientific literature on Precision Nursing are essentially about nursing clinical practice, in greater number, and nursing research.

**Keywords:** Nursing Precision; Precision Medicine; Personal Health Services; Biological Variation, Individual; Individuality; Health Records, Personal.

## RESUMEN

**Objetivo:** Analizar la producción científica sobre la enfermería de precisión. **Método:** Revisión bibliográfica integradora realizada en enero de 2020, en 8 bases de datos: SCOPUS, CINAHL, PubMed/MEDLINE, COCHRANE, Web of Science, EMBASE, LILACS/BDENF y SciELO, identificando 13 publicaciones que cumplieron los criterios de inclusión. La revisión integradora cumplió con las recomendaciones proporcionadas en la Declaración PRISMA. **Resultados:** Los estudios se centran en la identificación de los hábitos de vida, el genotipo, el fenotipo y de los biomarcadores, tales como: la glucemia, los lípidos, la creatinina y el índice de masa corporal y sus relaciones con los resultados, la aplicación y la prueba de los cuidados de enfermería específicos, que consideraron la condición de ese paciente para prevenir las complicaciones y están destinados a mejorar la calidad de vida. También se mencionó la importancia del uso de herramientas que ayuden a los investigadores en la aplicación de los fundamentos de la enfermería de precisión como: base de datos, herramientas para el análisis de datos, y otros. **Conclusión:** Las producciones encontradas en la literatura científica sobre la Enfermería de Precisión son esencialmente sobre la práctica clínica en enfermería, en mayor número, y la investigación en enfermería.

**Descriptorios:** Enfermería de Precisión; Medicina de Precisión; Atención Individual de Salud; Variación Biológica Individual; Individualidad; Registros de Salud Personal.

## INTRODUÇÃO

A prática de Enfermagem contempla na sua filosofia, código de ética, valores morais e cuidado individualizado, para tanto, centra-se na singularidade, individualidade e integridade do ser humano. A própria COVID-19 reiterou a necessidade de cuidados individualizados, uma vez que a infecção pelo coronavírus demonstra um comportamento variado, desde infecções assintomáticas, alguns pacientes desenvolvem casos leves, entretanto, por outro lado, outros pacientes

desenvolvem casos graves da doença, podendo evoluir a óbito. O que demonstra a complexa interação entre o hospedeiro humano e o coronavírus (OMS, 2020; Işık; Yildirim, 2023).

Uma série de processos estão envolvidos na resposta imunológica contra o coronavírus, como a resposta inata e adaptativa, barreiras teciduais, mediadores de moléculas moduladoras. Além disso, a variabilidade genética influencia na suscetibilidade a infecções por doenças contagiosas, enquanto alguns genes apresentam maior vulnerabilidade a COVID-19, outros estão mais propensos a desenvolverem imunidade baseada nas células T. A heterogeneidade da população também contribui para a variabilidade na reatividade cruzada e suscetibilidade à infecção (Işık; Yildirim, 2023).

Desta forma, em nenhum outro momento foi tão necessário a busca por posicionar o indivíduo no centro do cuidado em saúde. Ao considerar as particularidades biológicas/genéticas, fenotípicas, psicossociais, contextuais e de hábitos de vida, nos remete a um cuidado mais assertivo e, conseqüentemente, mais efetivo aos pacientes, mas também exerce influência na assertividade junto aos familiares e comunidade.

Nesse contexto, agrega-se a Enfermagem de Precisão, que pode ser definida como o atendimento às necessidades específicas de um único paciente a partir da associação de um conjunto de dados, incluindo doenças de base, características biológicas/genética, informações sociais, demográficas, biológicas e hábitos de vida (Lopes Júnior, 202a). Essa junção e processamento de dados ocorre por meio de tecnologias digitais em saúde como prontuário eletrônico do paciente, *smartphones* e relógios/pulseiras/braceletes inteligentes e óculos, também chamados de equipamentos vestíveis. Os quais fornecem informação aos enfermeiros que auxiliam na tomada de decisão (Yuan, 2015; Corwin; Ferranti, 2016).

A Enfermagem de Precisão reúne informações sobre o paciente, incluindo sinais, sintomas e biomarcadores para identificação de mecanismos biológicos subjacentes que caracterizam uma situação de doença para encontrar aqueles pacientes que possam se beneficiar e melhor se ajustar a uma orientação de precisão. O que é possível devido a testes e adaptação de biomarcadores a intervenções de enfermagem. A Enfermagem de Precisão também se preocupa com a igualdade em saúde, buscando aniquilar as desigualdades em saúde, por esse motivo essa ciência

desenvolve-se reafirmando o seu compromisso com a justiça social (Corwin; Ferranti, 2016; Lopes Júnior, 2021a).

Nesse ínterim, as tecnologias em saúde, por exemplo, a inteligência artificial, surge como aliada dos profissionais de saúde e pacientes. Essas tecnologias possibilitam a análise de grandes bancos de dados o que contribui para a vigilância em saúde e para identificação de pacientes semelhantes que melhor se ajustam às orientações de precisão (Bragazzi *et al.*, 2020; Menon *et al.*, 2019).

O presente artigo foi elaborado com o objetivo de analisar a produção científica acerca da Enfermagem de Precisão e teve como pergunta norteadora: Qual é o estado da arte descrito na literatura científica sobre Enfermagem de Precisão?

## **MÉTODO**

Trata-se de uma revisão integrativa da literatura, desenvolvida a partir do protocolo para revisão integrativa apresentado no Apêndice A. Esse método de pesquisa reúne e sistematiza resultados de pesquisa sobre uma determinada área de estudo, para fornecer as melhores evidências, bem como, o embasamento da prática clínica e a tomada de decisão. Este método contribui para a identificação de lacunas na produção do conhecimento científico e direciona a realização de novos estudos a partir da síntese do conhecimento sobre uma temática (Mendes; Silveira; Galvão, 2008).

A revisão de literatura foi desenvolvida com base em seis etapas sequenciais e independentes, são elas: 1) Identificação da temática e elaboração da pergunta de pesquisa; 2) Definição de critérios de inclusão e exclusão das produções científicas e busca nas bases de dados; 3) Definição das informações para compor o banco de dados e a categorização dos artigos 4) Avaliação criteriosa dos estudos selecionados 5) Análise dos dados 6) Síntese da revisão (Mendes; Silveira; Galvão, 2008). A revisão integrativa atendeu as recomendações previstas no *PRISMA Statement* (Moher *et al.*, 2009).

A busca eletrônica foi realizada no mês de janeiro de 2020, em 8 bases de dados: SCOPUS, *Cumulative Index to Nursing and Allied Health Literature* (CINAHL), *Medical Literature Analysis and Retrieval System Online* (PubMed/MEDLINE),

COCHRANE, *Web of Science*, EMBASE, Literatura Latino-Americana e do Caribe em Ciências da Saúde (LILACS/BDENF) e *Scientific Eletronic Library Online* (SciELO).

Utilizaram-se dos descritores disponíveis no *Medical Subject Headings* (MeSH) e no Descritores em Ciências da Saúde (DeCS), nos idiomas português, inglês e espanhol, com uso do operador booleano *OR*. Aplicaram-se estratégias de busca específicas para cada base de dados, as quais foram revisadas com bibliotecário e estão expostas no Quadro 1.

Quadro 1 - Estratégia de busca e referências identificadas.

<b>Bases de dados</b>	<b>Estratégia de busca</b>	<b>Referências identificadas</b>
Scopus	TITLE-ABS-KEY("Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing")	<b>149</b>
CINAHL	"Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing"	<b>136</b>
PubMed/MEDLINE	"Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing"	<b>129</b>
Cochrane	"Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing"	<b>117</b>
<i>Web of Science</i>	TS=("Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing")	<b>92</b>
EMBASE	"Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing"	<b>30</b>
LILACS/BDENF	"Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing" OR "Enfermagem de Precisão" OR "Enfermagem Individualizada" OR "Enfermagem personalizada" OR "Enfermería de precisión" OR "Enfermería individualizada" OR "Enfermería personalizada"	<b>25</b>
SciELO	"Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing" OR "Enfermagem de Precisão" OR "Enfermagem Individualizada" OR "Enfermagem personalizada" OR "Enfermería de precisión" OR "Enfermería individualizada" OR "Enfermería personalizada"	<b>12</b>
<b>Total</b>		<b>690</b>

Fonte: Elaborado pela autora (2021).

Os critérios de inclusão consistiram em artigos originais e editoriais, disponíveis na íntegra, nos idiomas português, inglês e espanhol, sem adotar recorte temporal. Foram considerados editoriais pelo ineditismo da temática e devido a

classificação do *Centre for Evidence-Based Medicine* incluir a opinião de especialistas como um nível de evidência. Excluíram-se publicações duplicadas, fora de escopo temático da pesquisa, revisões integrativas, teses e dissertações.

Os artigos foram classificados a partir do nível de evidência de acordo com a divisão proposta pelo *Centre for Evidence-Based Medicine*: 1A – Revisão sistemática de ensaios clínicos controlados randomizados; 1B – Ensaio clínico controlado randomizado com pequeno intervalo de confiança; 1C – Estudos sobre resultados terapêuticos; 2A – Revisão sistemática de estudos de coorte; 2B – Estudo de coorte, inclusive ensaio clínico randomizado de menor qualidade; 2C – Observação de resultados terapêuticos e estudo ecológico; 3A - Revisão sistemática de estudos caso-controle; 3B - Estudo caso-controle; 4 - Relato de casos, inclusive coorte ou caso-controle de menor qualidade; e 5 - Opinião de especialistas (University of Oxford, 2009).

Utilizou-se do *software Mendeley* para auxiliar na organização das publicações por base de dados e identificação de artigos duplicados. As informações foram organizadas em um banco de dados que investigou: título do artigo, link de acesso, base de dados, autores, vinculação do primeiro autor, Estado/País, periódico, ano de publicação, descritores, objetivo, método, cenário do estudo, população, principais achados e aspectos relacionados a Enfermagem de Precisão.

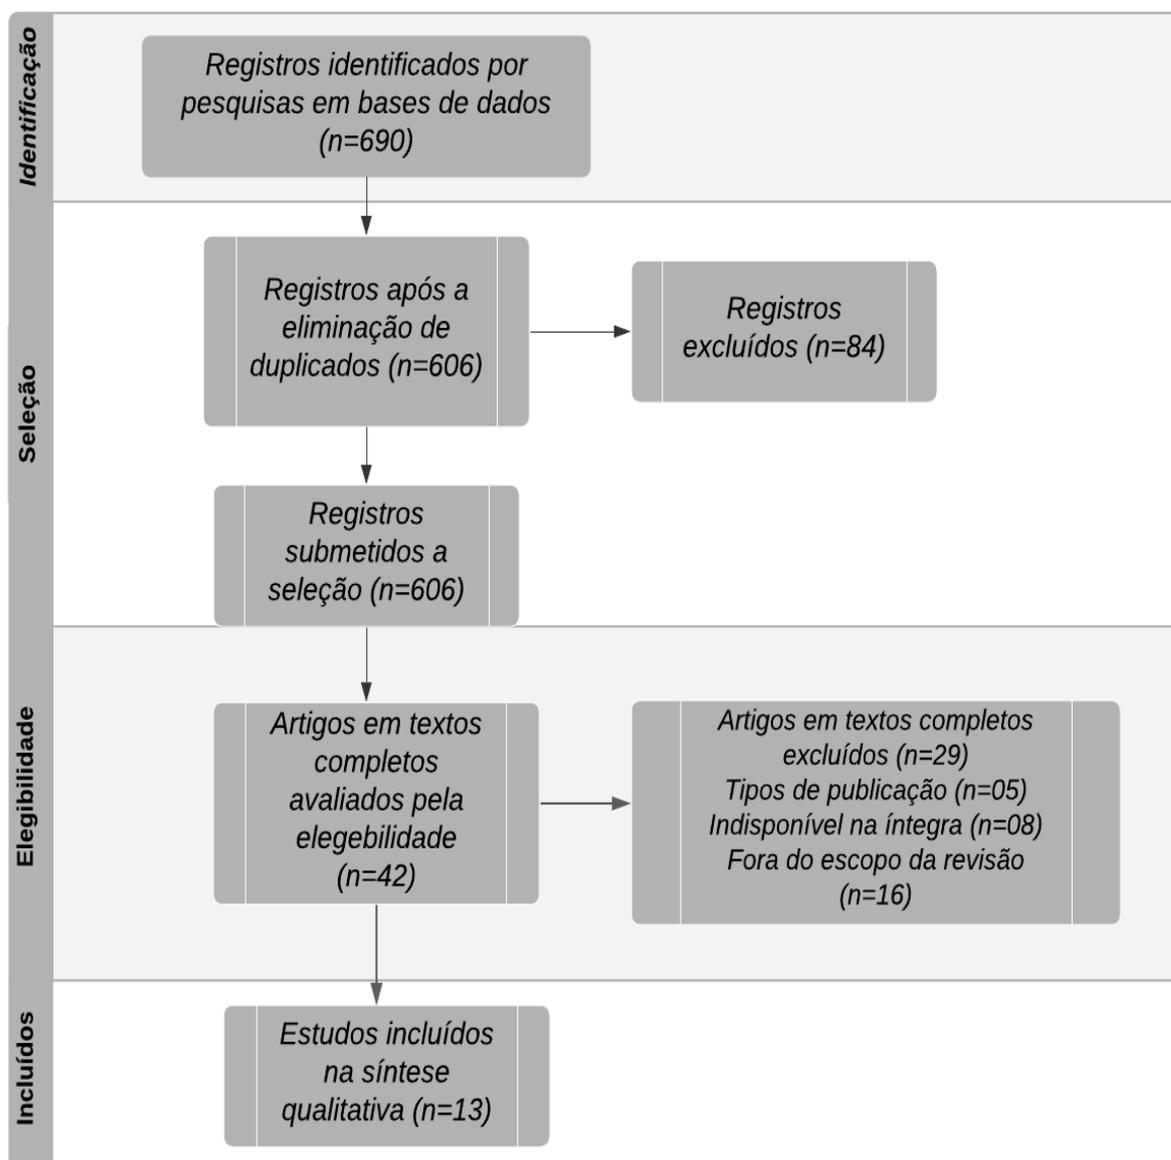
A análise dos dados foi realizada mediante análise qualitativa comparativa dos conceitos de Enfermagem de Precisão adotados nos artigos, os avanços da área, bem como do seu potencial para aplicação na prática clínica. A partir disso, foi realizada uma avaliação crítica dos artigos primários relacionados com a literatura científica sobre a temática.

## RESULTADOS

A partir dos cruzamentos, foram identificadas 690 publicações, eliminaram-se 84 artigos duplicados, ou seja, que estão em mais de uma base de dados. Assim, restaram 606 publicações para leitura dos títulos e resumos. Na etapa de elegibilidade, preencheram os critérios para leitura na íntegra 42 publicações, destas, excluíram-se 16 artigos fora do escopo da revisão, 8 pela indisponibilidade de leitura na íntegra e 5 pelo tipo de publicação, totalizando 29 artigos excluídos. Por fim,

selecionaram-se 13 artigos para compor os resultados da revisão, conforme demonstrado na Figura 4, na qual constam as etapas do processo de seleção dos artigos até a obtenção da amostra final de acordo com o modelo PRISMA.

Figura 4 - Fluxograma de Identificação, Seleção e Inclusão dos Estudos.



Fonte: Elaborado pela autora (2021).

Dentre os artigos selecionados, sete estudos (54%) são de natureza qualitativa, tendo como método opinião de especialistas e revisões de literatura e seis artigos (46%), são estudos quantitativos, ensaios clínicos controlados randomizados, caso-controle e relato de caso. Quanto ao ano de publicação, cinco artigos (38%)

foram publicados em 2020; seguido de três publicações (23%) em 2019; nos anos de 2014 a 2018 foram publicados um artigo por ano (8%).

Quanto ao país de estudos dos primeiros autores, seis artigos (46%) foram oriundos dos Estados Unidos da América; três estudos (23%) originários da China; e Inglaterra, Roma, Grécia e Austrália tiveram um estudo (8%) oriundo de cada um desses países. Os 13 artigos (100%) artigos foram escritos na língua inglesa.

Quanto a fonte dos dados, quatro estudos (31%) obtiveram os dados provenientes da literatura científica; dois estudos (15%) tiveram como população gestantes e puérperas; um estudo (8%) foi realizado com idosos; um estudo (8%) abordou pacientes com diabetes mellitus tipo 2; um editorial (8%) acerca da aplicação de Enfermagem de Precisão na atenção aos cuidados oncológicos; um estudo (8%) apontou as diretrizes orientativas a pesquisas de Enfermagem de Precisão integradas às estruturas já existentes; um estudo (8%) teve como população mulheres em tratamento contra o câncer; um estudo (8%) foi realizado com diretores de centros de pesquisa e um estudo (8%) investigou cateteres intravenosos periféricos. O Quadro 2 apresenta a amostra de artigos selecionada para a revisão.

Quadro 2 - Artigos incluídos na amostra ordenados pelo ano de publicação e nível de evidência.

Autores Ano	Tipo de estudo/ Nível de evidência	Enfermagem de Precisão
Keogh <i>et al.</i> (2020)	Ensaio clínico randomizado de cluster 1B	Uma intervenção multifacetada combinando educação clínica, reforço das diretrizes de lavagem de cateteres intravenosos periféricos e uso de produto complementar, com seringas de lavagem pré-cheias, preparadas pelo fabricante, contribuiu para a precisão e eficiência na redução da proporção e o risco de falha de cateteres intravenosos periféricos.
Li <i>et al.</i> (2020)	Estudo caso-controle 3B	A partir de biomarcadores (glicemia, lipídios, creatinina, IMC) foram implementadas intervenções específicas de enfermagem: educação em saúde, intervenção dietética, intervenção de exercícios, intervenção de medicamentos e prevenção de complicações para pacientes com diabetes, as quais melhoraram a qualidade de vida dos pacientes.
Ielapi <i>et al.</i> (2020)	Opinião de especialistas 5	Os biomarcadores clínicos, imagens e ômicas (genômica, transcriptômica, proteômica e metabolômica) podem fornecer informações úteis sobre suscetibilidade a doenças, exposição, evolução e resposta ao tratamento. Portanto, apresentam capacidade de impactar positivamente o gerenciamento de saúde.

Fu <i>et al.</i> (2020)	Opinião de especialistas 5	As funções de enfermagem são primordiais na implementação da saúde de precisão, como: a administração precisa de medicamentos com base no conhecimento da farmacogenética; a educação ao paciente e à família sobre o significado dos testes genômicos ou ômicos; nas avaliações de saúde, incluindo o histórico familiar; no fornecimento de informações críticas, feedback e visão sobre a viabilidade de implementação de novas tecnologias em fluxos de trabalho, no ponto clínico de atendimento.
Spanakis, Patelarou, Patelarou (2020)	Opinião de especialistas 5	A assistência à saúde voltada para a precisão requer que o cuidado de enfermagem personalizado seja bem-informado e competente em sua compreensão, síntese e aplicação desses avanços na ciência. A educação em enfermagem e a educação continuada, o suporte à decisão clínica e as mudanças nos sistemas de saúde serão necessárias para proporcionar aos pacientes cuidados multidisciplinares personalizados, nos quais os enfermeiros desempenham um papel fundamental. Isso exigirá tanto a capacitação da força de trabalho existente quanto uma nova abordagem para a educação das gerações futuras, no que tange o ensino da genética, genômica, matemática, estatística, ética e ciências da informática/tecnologia da informação e comunicação (TICs).
Zheng, <i>et al.</i> (2019)	Estudo caso controle 3B	A partir do fenótipo de fragilidade dos idosos foram implementados cuidados precisos de enfermagem.
Menon, <i>et al.</i> (2019)	Relato de caso 4	A Estrutura ConNECT fornece um conjunto simples de diretrizes gerais que permitem um enfoque abrangente e contextualmente rico para orientar a pesquisa em saúde de precisão e que pode ser integrado às estruturas existentes.
Hickey <i>et al.</i> (2019)	Opinião de especialistas 5	O espectro da saúde de precisão abrange o código genético e oferece a oportunidade para os cientistas enfermeiros liderarem o avanço da ciência dos sintomas e do autogerenciamento.
Founds, Tsigas, Ren, Barmada (2018)	Ensaio clínico controlado 1B	Associação dos sintomas ao genótipo na pré-eclâmpsia, o que pode abrir caminho para uma fenotipagem mais holística das mulheres durante a gravidez para informar os subgrupos suscetíveis a patologias específicas na pré-eclâmpsia. A identificação de sintomas anteriores ou padrões de sintomas pode sinalizar a necessidade de maior frequência e qualidade de vigilância com intervenção precoce para a mãe e o feto.
Lanceley <i>et al.</i> (2017)	Ensaio clínico controlado randomizado 1B	O acompanhamento individualizado realizado por enfermeiros em pacientes oncológicos, mostrou-se superior ao tratamento convencional, no que se refere a qualidade de vida, satisfação do paciente e atraso na recidiva sintomática do câncer.
Corwin, Ferranti (2016)	Relato de caso 4	A utilização de biomarcadores para identificar objetivamente os riscos à saúde e expor os mecanismos subjacentes a esses riscos, oferece a oportunidade para pesquisadores, enfermeiros e médicos desenvolverem, direcionarem e avaliarem intervenções personalizadas para melhorar a saúde das gerações futuras. A contribuição de fatores biocomportamentais, incluindo exposição ao estresse crônico, sobre o microbioma e parto prematuro em mulheres afro-americanas.

Yuan (2015)	Opinião de especialistas 5	Ressalta a importância da Enfermagem de Precisão para prestação de cuidados individualizados e precisos, de acordo com as características daquele ser humano. Para tanto, conta com banco de dados, ferramenta de análise de dados, entre outros.
Munro (2015)	Documento de discussão 5	Há uma necessidade de desenvolvimento de pesquisas genéticas/genômicas que abordem diretamente questões vitais para a ciência da enfermagem, incluindo estudos de plausibilidade biológica. A pesquisa também é necessária para informar a concepção e entrega de intervenções de enfermagem para doenças complexas. A previsão de respostas às intervenções de enfermagem com base na variabilidade individual pode aumentar a probabilidade de que a primeira intervenção empregada leve a resultados ideais para cada paciente.

Fonte: Elaborado pela autora (2021).

## DISCUSSÃO

Os estudos centram-se na identificação de hábitos de vida, genótipo, fenótipo e de biomarcadores – como, glicemia, lipídios, creatinina e Índice de Massa Corpórea (IMC) – e suas relações com desfechos como, por exemplo: parto prematuro. Em outras situações, a partir da identificação inicial de fatores comportamentais, genética e fenótipo foram implementados e testados cuidados específicos de enfermagem, como intervenção dietética, de exercício, medicamentos e educação em saúde, as quais consideraram a condição daquele paciente para prevenção de complicações e voltam-se para a melhoria da qualidade de vida. Também foi mencionada a importância da utilização de ferramentas que auxiliam os pesquisadores na aplicação dos fundamentos de Enfermagem de Precisão como: banco de dados, ferramentas para análise de dados, e outras.

Observa-se pouca expressividade de pesquisas clínicas aplicadas à prática assistencial da enfermagem, visto que, dos 13 estudos que compõem a revisão integrativa, menos da metade tratam de uma aplicação clínica de Enfermagem de Precisão. O que demonstra que embora os autores estejam apropriados dos conceitos, precisamos evoluir no sentido de testar aplicações práticas de integração de biomarcadores que forneçam intervenções mais precisas de enfermagem, melhorando a saúde e o bem-estar de pacientes, famílias e comunidades ao longo da vida (Corwin; Ferranti, 2016). Esse dado aponta a direção para a necessidade de investimentos em pesquisa clínica em enfermagem, tendo como método, ensaio

clínico controlado randomizado, estudos de coorte e que apresentem resultados terapêuticos das intervenções realizadas.

Em um estudo exploratório realizado em 2018, os pacientes relataram níveis moderados a altos de cuidados individualizados durante a radioterapia. Pode ser bastante desafiador para os enfermeiros prestarem cuidados individualizados a cada paciente. No entanto, somente informações demográficas e as percepções relatadas pelos pacientes em relação aos cuidados individualizados recebidos fornecem uma visão limitada sobre o cuidado. A exploração de outros biomarcadores do paciente pode auxiliar na observação de novas nuances para a adaptação de intervenções e a melhoria do atendimento aos pacientes submetidos à radioterapia (Rose, 2018).

A inclusão de biomarcadores mensuráveis, como sinais vitais e resultados de exames do paciente conferem potencial para avanço da ciência da enfermagem. Nesse sentido, o autorrelato do paciente e monitoramento dos sintomas auxiliam como uma forma de avaliação subjetiva de uma determinada intervenção, enquanto o monitoramento de alterações dos biomarcadores fornece evidências que subsidiam apoiar ou refutar determinada hipótese que embasou a aplicação de determinada intervenção. Uma intervenção de Enfermagem de Precisão orienta-se por hipóteses e ao mesmo tempo adapta-se a um único indivíduo, dessa forma, os pesquisadores de enfermagem estão mais suscetíveis a entender mecanismos biológicos subjacentes que impedem a homeostase do organismo, também contribuem para estratégias mais precisas no futuro (Corwin; Ferranti, 2016).

Por outro lado, em algumas situações, como é o caso do Robô Laura, não é utilizado o termo Enfermagem de Precisão, entretanto, os enfermeiros participam ativamente no levantamento de biomarcadores precoces para a identificação de sepse. Após identificadas as variáveis, vão além e procuram entender o quanto essa tecnologia impacta na prática assistencial de enfermagem aos pacientes com sepse e nas tomadas de decisão dos profissionais da saúde (Gonçalves *et al.*, 2020).

Embora neste estudo não se tenha definido um recorte temporal, justamente para analisar a linha do tempo da produção científica relacionada à Enfermagem de Precisão, verificou-se que os estudos começaram a ser publicados a partir de 2014, com o maior número de publicações em 2020. A temática da precisão na área da saúde, ganhou maior notoriedade nos Estados Unidos, em 2015, quando foi lançado o projeto denominado "*All of Us*". O estudo de coorte longitudinal, prevê o

acompanhamento de variáveis genéticas, ambientais, psicossociais e demográficas de um milhão de estadunidenses por 10 anos (Fu *et al.*, 2020). O que também pode justificar o maior número de publicações serem oriundas dos Estados Unidos. Entretanto, estudos associando fenótipos e precisão já haviam sido publicados em 2012 por pesquisador alemão e países como China, França, Reino Unido e Índia também desenvolvem estudos semelhantes (Robinson, 2012; Fu *et al.*, 2020).

A busca pela precisão começa a ser vista também no âmbito da administração de medicamentos. Ao abordar a precisão relacionada a quantidade de volume administrada e a funcionalidade desses dispositivos.

No ano de 2011, um estudo já abordava a precisão de medicamentos, no sentido de analisar a quantidade correta de volume administrada, previamente à publicação dos primeiros conceitos e estudos sobre Enfermagem de Precisão. Assim, acredita-se que já era os primórdios de uma era voltada para a precisão. Na pesquisa, foi identificado um volume residual de 10,2 a 15,3 ml nos equipos de soluções parenterais, para administração de medicamentos por via endovenosa. O volume residual foi eliminado ao utilizar-se equipo com bureta e ao administrar 20 ml soro fisiológico 0,9% na extensão do equipo (Silva; Furlan; Fabrício-Wehbe, 2011). Outro estudo realizado sobre a precisão na administração de medicamentos, desta vez em 2020, utilizou da intervenção de lavagem de cateteres intravenosos periféricos e observou que esta contribui para a redução de falhas no seu funcionamento e aumento da sua eficiência e precisão na administração de medicamentos (Keogh *et al.*, 2020). A administração de medicamentos é uma atividade de competência dos profissionais de enfermagem e contribui para a efetividade das respostas terapêuticas.

Um estudo realizado por Menon *et al.* (2019) voltou-se para ferramentas orientativas para pesquisas na área da Enfermagem de Precisão. Em decorrência da complexa interação de fatores que afetam a saúde, considerando aqui as iniquidades em saúde, propôs a estrutura ConNECT como uma ferramenta promissora para orientação de pesquisas em saúde de precisão na área da enfermagem, baseada em 5 princípios amplos e sinérgicos, são eles:

Quadro 3 - Estrutura ConNECT para orientação de pesquisas em Enfermagem de Precisão.

<b>Princípio 1</b>	Integrar o contexto: integração e análise de big data entre o contexto biológico, social e ambiental, como análise dos dados ômicas (metabolômica, proteômica, genômica e transcriptômica) e biologia dos sistemas, para alcançar a saúde de precisão.
<b>Princípio 2</b>	Promover a inclusão: diminuir as iniquidades em saúde ao recrutar para as pesquisas uma amostra de estudo representativa da população, atentar-se para a inclusão de grupos pouco expressivos nas pesquisas.
<b>Princípio 3</b>	Garantir a difusão equitativa de inovações: garantir a difusão do conhecimento de pesquisas em saúde de precisão, assegurando que as inovações tecnológicas sejam acessíveis a toda a população.
<b>Princípio 4</b>	Aproveitar a Tecnologia de Comunicação: utilizar as inovações tecnológicas de modo a alcançar o cuidado equitativo em saúde.
<b>Princípio 5</b>	Priorizar treinamento especializado: fornecer educação continuada em ciências da saúde de precisão a partir do ensino de graduação.

Fonte: Adaptado de Menon *et al.* (2019).

Os cinco princípios podem ser adotados pelos enfermeiros pesquisadores em Enfermagem de Precisão de modo a priorizar determinadas especificidades do estudo. Embora sejam princípios sequenciais, podem ser utilizados de maneira aleatória de acordo com as necessidades da pesquisa. Acredita-se que a adoção da estrutura ConNect para compreensão da complexidade das interações bases da saúde humana, embasa de maneira simples e prática a pesquisa em Enfermagem de Precisão e corrobora para sua disseminação de modo a provocar um maior impacto na saúde da população (Menon *et al.*, 2019).

O presente estudo apresentou limitações relacionadas ao método da pesquisa, devido à baixa quantidade de pesquisas sobre a temática em voga, também foram incluídas no estudo revisões de literatura e opinião de especialistas. Além disso, foram considerados apenas os idiomas inglês, português e espanhol para a seleção dos artigos por serem compreendidos pelos autores.

O estudo avança no sentido de apresentar uma estrutura para orientação de pesquisas em Enfermagem de Precisão (ConNECT), incluindo a necessidade de mais estudos clínicos e amostras representativas da população, o que garante uma diversidade genômica e uma compreensão aprofundada de perspectivas culturais, aumentando as possibilidades de generalização dos achados. A criação de grandes

bancos de dados com cruzamento de informações, por exemplo, laboratoriais, de hábitos de vida, genética fornece informações que favorecem o entendimento dos enfermeiros acerca das características dos pacientes e quais cuidados de enfermagem podem favorecê-lo.

Para tanto, é premente a inclusão de conhecimentos em genética e letramento em saúde digital com conhecimentos em banco de dados e ferramentas de análise de dados na formação do enfermeiro generalista, alimentando estes domínios ainda na graduação. A estrutura de ensino desde cursos de graduação e, também, formações mais aprofundadas com especialização *latu e strictu sensu* formará enfermeiros mais bem preparados para encarar uma nova era de cuidados em saúde.

## **CONCLUSÃO**

Ao analisar a produção científica acerca da Enfermagem de Precisão conclui-se que as produções encontradas versam essencialmente sobre a prática clínica em enfermagem, em maior número, e a pesquisa em enfermagem. Em relação a pesquisa, um dos artigos propõe uma estrutura orientativa para as pesquisas em Enfermagem de Precisão, o que pode ser um início para os enfermeiros adentrarem na temática.

No âmbito das pesquisas sobre a prática clínica de Enfermagem de Precisão evidenciou-se a identificação de biomarcadores, genótipo, fenótipo e fatores comportamentais. Essas variáveis foram associadas a educação em saúde, intervenções de exercícios físicos e dietéticas para observação de possíveis desfechos. O conhecimento gerado foi aplicado para prevenção de complicações de saúde dos pacientes e melhoria da sua qualidade de vida.

Ainda, em relação a Enfermagem de Precisão voltada para a prática clínica, acredita-se que a aplicação de medicamentos em exatidão possa desenvolver-se como uma subárea da Enfermagem de Precisão. A administração de medicamentos é uma das atividades que compete aos profissionais da enfermagem e em muito contribui para o sucesso da terapêutica medicamentosa e conseqüentemente apresenta influência no curso evolutivo da doença.

## REFERÊNCIA

- BRAGAZZI, N. L. *et al.* How big data and artificial intelligence can help better manage the covid-19 pandemic. **International Journal of Environmental Research and Public Health**, v. 17, n. 9, p. 3176, 2 maio 2020. DOI: 10.3390/ijerph17093176.
- CORWIN, E. J.; FERRANTI, E. P. Integration of biomarkers to advance precision nursing interventions for family research across the life span. **Nursing outlook**, v. 64, n. 4, p. 292–298, 2016. DOI: 10.1016/j.outlook.2016.04.007
- FOUND, S. A.; TSIGAS, E.; REN, D.; BARMADA, M. M. Associating Symptom Phenotype and Genotype in Preeclampsia. **Biological research for nursing**, v. 20, n. 2, p. 126–136, mar. 2018. DOI: 10.1177/1099800417754140
- FU, M. R. *et al.* Precision health: A nursing perspective. **International Journal of Nursing Sciences**, v. 7, n. 1, p. 5, 10 jan. 2020. DOI: 10.1016/j.ijnss.2019.12.008
- GONÇALVES, L. S. *et al.* Implantação de algoritmo de inteligência artificial para detecção da sepse. **Revista Brasileira de Enfermagem**, v. 73, n. 3, p. e20180421, 9 abr. 2020. DOI: <https://doi.org/10.1590/0034-7167-2018-0421>
- IELAPI, N. *et al.* Precision Medicine and Precision Nursing: The Era of Biomarkers and Precision Health. **Int J Gen Med.**, v. 13, p. 1705-171, dez. 2020. DOI: 10.2147/IJGM.S285262.
- IŞIK, M. T.; YILDIRIM, G. Individualized care perceptions and moral distress of intensive care nurses. **Nursing in Critical Care**, v. 28, n. 2, 2023. DOI: 10.1111/nicc.12715
- KEOGH, S. *et al.* Implementation and evaluation of short peripheral intravenous catheter flushing guidelines: A stepped wedge cluster randomised trial. **BMC Medicine**, v. 18, n. 252, p. 1–11, 30 set. 2020. DOI: <https://doi.org/10.1186/s12916-020-01728-1>
- LANCELEY, A. *et al.* Ovarian Cancer Follow-up: A Preliminary Comparison of 2 Approaches. **International Journal of Gynecologic Cancer**, v. 27, p. 59-68, 2017.
- LI, Z. *et al.* Analysis of risk factors of diabetes peripheral neuropathy in type 2 diabetes mellitus and nursing intervention. **Exp Ther Med.**, v. 20, n. 6, p. 127, 2020. DOI: 10.3892/etm.2020.9257.
- LOPES JÚNIOR, L. C. Personalized Nursing Care in Precision-Medicine Era. **SAGE Open Nursing**, v. 7, 9 dez. 2021a. DOI: 10.1177/23779608211064713
- MENDES, K. D. S.; SILVEIRA, R. C. DE C. P.; GALVÃO, C. M. Revisão integrativa: método de pesquisa para a incorporação de evidências na saúde e na enfermagem. **Texto & Contexto - Enfermagem**, v. 17, n. 4, p. 758–764, dez. 2008. Disponível em: <https://www.redalyc.org/articulo.oa?id=71411240017>. Acesso em: 15 jul. 2022.

MENON, U. *et al.* Precision health research and implementation reviewed through the conNECT framework. **Nursing outlook**, v. 67, n. 4, p. 302–310, jul./ago. 2019. DOI: <https://doi.org/10.1016/j.outlook.2019.05.010>

MOHER, D. *et al.* Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. **PLoS Medicine**, v. 6, n. 7, jul. 2009. DOI: <https://doi.org/10.1371/journal.pmed.1000097>

MUNRO C. L. Individual genetic and genomic variation: a new opportunity for personalized nursing interventions. **Journal of Advanced Nursing**, v. 71, n. 1, p. 35–41, 2015. DOI: 101111/jan.12552

UNIVERSITY OF OXFORD. Oxford Centre for Evidence-Based Medicine. **Oxford Centre for Evidence-Based Medicine: Levels of Evidence** (March 2009). Oxford, 2009. Disponível em: <https://www.cebm.ox.ac.uk/resources/levels-of-evidence/oxford-centre-for-evidence-based-medicine-levels-of-evidence-march-2009>. Acesso em: 24 jan. 2022.

OMS. Organização Mundial da Saúde. **Transmission of SARS-CoV-2: implications for infection prevention precautions**. 9 jul. 2020. Disponível em: <https://www.who.int/news-room/commentaries/detail/transmission-of-sars-cov-2-implications-for-infection-prevention-precautions>. Acesso em: 26 jan. 2022.

ROBINSON, P. N. Deep phenotyping for precision medicine. **Human Mutation**, v. 33, n. 5, p. 777–780, 1 maio 2012. DOI: 10.1002/humu.22080

ROSE, P. M. Patients' characteristics informing practice: improving individualized nursing care in the radiation oncology setting. **Supportive Care in Cancer**, v. 26, n. 10, p. 3609–3618, 1 out. 2018. DOI:10.1007/s00520-018-4210-5

SILVA, V. L. dos S.; FURLAN, M. L. de S.; FABRÍCIO-WEHBE, S. C. C. Identificação do volume residual em equipos de soluções parenterais após administração de medicamentos. **Rev. enferm. UERJ**, v. 19, n. 2, p. 192–197, 2011. Disponível em: <http://www.revenf.bvs.br/pdf/reuerj/v19n2/v19n2a04.pdf>. Acesso em: 24 jan. 2022.

SPANAKIS, M.; PATELAROU, A. E.; PATELAROU, E. Nursing Personnel in the Era of Personalized Healthcare in Clinical Practice. **Journal of Personalized Medicine**, v. 10, n. 3, p. 1–19, 1 set. 2020. DOI: 10.3390/jpm10030056

ZHENG, X. *et al.* The effect of three-stage preventive nursing on older patients with frailty. **Journal of the American Geriatrics Society**, v. 67, n. 10, S664-S665, 2019.

YUAN, C. Precision Nursing: New Era of Cancer Care. **Cancer Nursing**, v. 38, n. 5, p. 333–334, 2015. DOI: 10.1097/NCC.0000000000000290

### 3.4 INICIATIVAS NACIONAIS PARA A SAÚDE DIGITAL E ALINHAMENTO DA PESQUISA A AGENDA NACIONAL E DAS AMÉRICAS

No que tange a informação em saúde, de 1920 a 1990 estava restrita a estatísticas sanitárias, com a finalidade de alimentar estratégias de controle do Estado. Durante este período, surgiram vários sistemas de informações isolados, prezando pelo desenvolvimento tecnológico em contraponto a definições sobre o conteúdo das informações. As Conferências Nacionais de saúde, em 1990, fomentaram discussões acerca da remodelação do sistema de saúde atual e da necessidade de uma política de informação para a área da saúde no Brasil. Assim surgiram outras iniciativas, a saber: a Rede Nacional de Informações em Saúde (RNIS), a Rede Interagencial de Informações para a Saúde (RIPSA) e o Cartão Nacional do SUS (Cartão SUS), voltadas para a produção de indicadores e infraestrutura computacional e de conectividade (Cavalcante *et al.*, 2015).

As iniciativas mencionadas anteriormente, contribuíram para a evolução e construção de políticas nacionais para a área, diante da necessidade de orientações que norteassem as ações de Tecnologia da Informação e Comunicação no sistema de saúde brasileiro.

Desta forma, em 2003 foi lançada no Brasil a Política Nacional de Informação e Informática em Saúde (PNIIS), a qual foi atualizada e a segunda versão foi publicada em 2016 e mais recentemente, em 2021, a terceira edição da política. As atualizações da última versão foram motivadas pelas transformações decorrentes da pandemia provocada pela COVID-19, como a regulamentação da telemedicina no Brasil e, pela Lei Geral de Proteção de Dados (LGPD), a qual prevê proteções específicas para a área da saúde. A PNIIS de 2021 em linhas gerais, versa sobre as diretrizes para interoperabilidade dos sistemas de informação em saúde, a governança da informação e a segurança de acesso às informações em saúde nos setores público e privado do Brasil, promovendo o acesso às informações em saúde pela população e a melhoria da saúde do cidadão (Brasil, 2021).

O Ministério da Saúde lançou em 2020 a Estratégia de Saúde Digital (ESD) do Brasil para 2020 a 2028, alinhada a PNIIS e as iniciativas governamentais anteriores, assume um caráter de complementaridade, reafirmando políticas, diretrizes e portarias aprovadas anteriormente. A ESD propõe 7 prioridades para o

plano de ação para a saúde digital 2020-2028, a saber: Prioridade 1: Governança e liderança para a ESD; Prioridade 2: Informatização dos três níveis de atenção; Prioridade 3: Suporte à melhoria da atenção à saúde; Prioridade 4: Os usuários da Saúde Digital como protagonista; Prioridade 5: Formação e capacitação de recursos humanos para a Saúde Digital; Prioridade 6: Ambiente de interconectividade e Prioridade 7: Ecossistema de inovação (Brasil, 2020a). No contexto da ESD, a Rede Nacional de Dados em Saúde (RNDS) fornece suporte para a integração de informações da Rede de Atenção à Saúde, permitindo a gestão do cuidado dos pacientes em todos os serviços de saúde (Brasil, 2020a).

O presente estudo está alinhado a prioridade 3 da ESD, a qual prevê o uso de inteligência e análises preditivas para triagem da população, por meio da coleta e tratamento de informações em saúde, oferece suporte à gestão de saúde populacional para o desenvolvimento de programas e políticas de saúde adequadas às necessidades oriundas de dados em saúde.

Dentre os Objetivos do Desenvolvimento Sustentável (ODS) no Brasil com metas a serem atingidas até 2030, a pesquisa se alinha-se ao Objetivo 3 – Saúde e bem-estar, e ao Objetivo 9 – Indústria, inovação e infraestrutura. Em relação ao 3º objetivo, busca-se garantir o acesso à saúde de qualidade e promover o bem-estar para todos, tendo como algumas das metas, acabar com as doenças transmissíveis e, melhorar a capacidade de países, principalmente os países em desenvolvimento, para alerta precoce e gerenciamento de riscos à saúde. No que se refere ao objetivo 9, busca-se o desenvolvimento de infraestruturas para apoiar o bem-estar humano; a adoção de tecnologias e processos menos poluentes; o fortalecimento da pesquisa científica e aumentar o acesso às TICs (Brasil, 2022).

Nas Américas, a pesquisa está alinhada à orientação da Organização Pan-Americana de Saúde (OPAS) na sua publicação dos oito princípios orientadores da transformação digital do setor da saúde. Entre oito princípios estão: conectividade universal, bens públicos digitais, saúde digital inclusiva, interoperabilidade, direitos humanos, segurança da informação, arquitetura de saúde pública e inteligência artificial. No que se refere à inteligência artificial, a orientação busca a cooperação global, em redes multissetoriais e interdisciplinares, compreendendo dimensões individuais e sociais em uma realidade globalizada. A OPAS alerta para a adoção de soluções inteligentes, como algoritmos abertos e confiáveis que garantam a inclusão

social, considerando abordagens equitativas em relação a gênero e diversidade cultural, desde a concepção até a aplicação. Também prevê incentivos financeiros a países menos favorecidos, para que possam se beneficiar das tecnologias advindas da inteligência artificial no cenário da saúde pública (OPAS, 2021).

### 3.5 INTELIGÊNCIA ARTIFICIAL

Não há um consenso na literatura sobre a definição de IA, por este motivo a sua conceituação não é uma tarefa trivial. Para Shimizu e Nakayama (2020) é considerada uma área de pesquisa voltada para o desenvolvimento de computadores, com o intuito de reproduzir a inteligência dos seres humanos. Enquanto para Contreras e Vehi (2018) é entendida como um ramo da ciência da computação voltado para criação de sistemas e métodos de análise de dados, de uma ampla e complexa gama de informações. Há ainda autores que fazem uma associação dos dois conceitos anteriores e definem IA como um termo amplo, que engloba sistemas e tecnologias capazes de reproduzir inteligência semelhante à humana (Kilic, 2020).

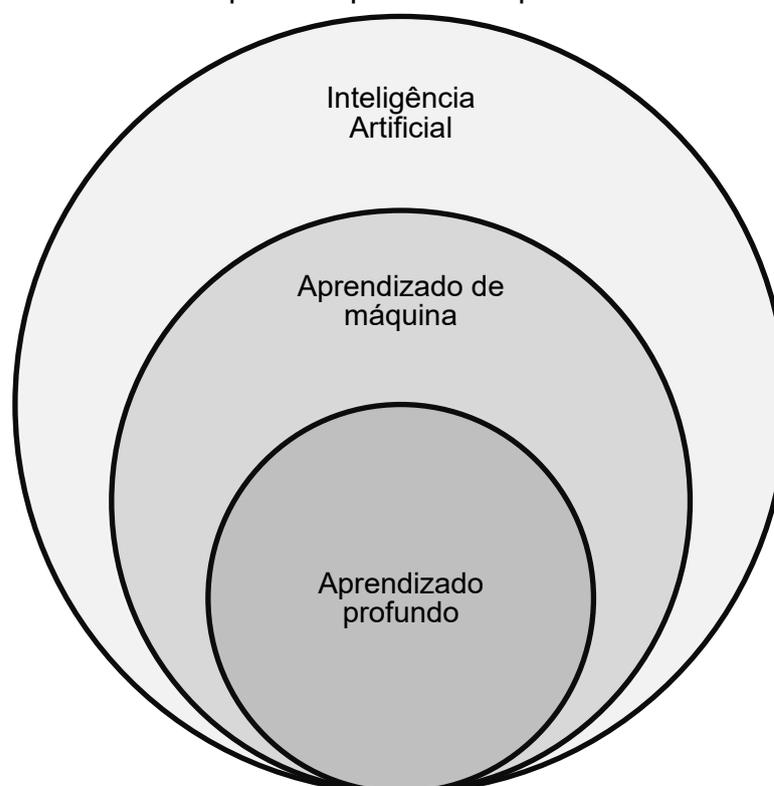
Embora não haja um consenso em relação ao conceito de IA, há uma concordância de que seus modelos mostram-se úteis para identificar detalhes dos dados em saúde que muitas vezes passam despercebidos pelos olhos humanos. Além disso, durante a pandemia provocada pela COVID-19 a IA mostrou-se uma ferramenta importante de atuação no enfrentamento do vírus. Em resposta às necessidades de gerenciamento da pandemia foram identificadas pelo menos seis áreas potenciais de contribuição da IA, são elas: emissão precoce de alertas, prevenção e rastreamento da doença, análise de dados, diagnóstico e prognóstico, tratamento e cura e controle da pandemia. Além disso, todas essas informações geram uma grande quantidade de dados úteis para o treinamento de modelos de IA (Al-Hashimi; Hamdan, 2021).

A área da saúde enfrenta desafios relacionados à extração, análise e aplicação da grande quantidade de dados estruturados e não estruturados, por este motivo observa-se uma crescente implantação da IA em ambientes de cuidado clínico, uma vez que essa tecnologia automatiza processos de gerenciamento de doenças, como reconhecimento de padrões e análise de dados. A partir da coleta e sintetização de informações iniciais, como sinais e sintomas e resultados de exames, aplicativos

de IA fornecem previsões, categorizam doenças, indicam diagnósticos e tratamentos e auxiliam no gerenciamento de doenças. Por meio dessas aplicações, além de contribuir para diagnóstico e tratamento, auxiliam na formação de protocolos de tratamento e monitoramento dos pacientes (Al-Hashimi; Hamdan, 2021).

A grande área da IA engloba outras subáreas, dentre as quais estão: o aprendizado de máquina e o aprendizado profundo, conforme demonstrado na Figura 6. O aprendizado de máquina é um subcampo da IA em que são aplicadas abordagens matemáticas e estatísticas para melhorar a performance dos computadores, enquanto o aprendizado profundo é um subcampo do aprendizado de máquina em que são reunidas técnicas mais atuais de redes neurais artificiais multicamadas e que apresentam bons resultados em tarefas específicas (Shimizu; Nakayama, 2020). Para fins de padronização, o presente estudo irá tratar os termos Inteligência Artificial e aprendizado de máquina como sinônimos, uma vez que, ao abordar o aprendizado de máquina refere-se a uma área de inteligência artificial.

Figura 5 - Relação entre os conceitos de inteligência artificial, aprendizado de máquina e aprendizado profundo.



Fonte: Elaborado pela autora (2023).

O aprendizado de máquina, subárea da inteligência artificial, é um método de análise de dados que, a partir de algoritmos que aprendem, com base em dados disponíveis, são capazes de extrair insights ocultos, que resultam na criação de modelos de decisão e automatização de processos (Cuocolo *et al.*, 2020).

Os algoritmos de aprendizado de máquina aprendem as relações entre os diferentes conjuntos de dados e a partir disto informam os resultados, entretanto, diferente dos métodos de análise estatística convencionais, não apresentam a necessidade de especificar explicitamente a relação exata entre os elementos dos dados. São cada vez mais utilizados na saúde, área que apresenta um grande número de variáveis, justamente pela sua capacidade de análise, espera-se que o aprendizado de máquina atue melhorando a prática clínica. Alguns estudos demonstram a eficiência dos modelos de aprendizado de máquina quando comparados às tarefas executadas por profissionais da área da saúde (Hou *et al.*, 2021).

Os algoritmos de aprendizado de máquina podem ser divididos em quatro subtipos: aprendizado supervisionado, não supervisionado, semi-supervisionado e aprendizado por reforço. O aprendizado não-supervisionado e o supervisionado são os mais conhecidos. A aprendizagem supervisionada está relacionada aos casos em que já se conhece as possíveis entradas e saídas e a atuação do algoritmo ocorre com mais precisão sobre as entradas e saídas, por exemplo, um algoritmo de regressão envolve saídas contínuas, enquanto a classificação envolve saídas não categóricas ou contínuas. No aprendizado não supervisionado, não são conhecidas as possíveis saídas, por isso o algoritmo aprende as características inerentes àquele banco de dados (Kilic, 2020). Para este estudo será utilizado o aprendizado supervisionado.

Algumas aplicações de IA no combate a pandemia foram utilizadas para diagnóstico médico por imagens, como exames de Raio-X; aplicativos de smartphone com inteligência artificial para monitoramento e avaliação de risco da COVID-19 (Al-Hashimi; Hamdan, 2021). Os modelos de aprendizado de máquina mostram-se úteis para criação de modelos de predição de IA em uma situação específica e analisando determinados dados, o que auxilia no estabelecimento de parâmetros clínicos. Estas aplicações são essenciais em um contexto mandatário para tomada de decisões e ao mesmo tempo com limitação de recursos e de tempo. Outro ponto relevante é a

praticidade dos modelos, os quais podem ser rapidamente aprimorados e re-treinados (Hou *et al.*, 2021).

Na área cardiovascular, uma aplicação de aprendizado de máquina utilizou-se de rede neural profunda para classificação de 12 ritmos em eletrocardiogramas. A classificação do algoritmo mostrou-se superior à de cardiologistas ao avaliar os mesmos eletrocardiogramas, com c-index de 0,97 e escore F1 de 0,837 (Kilic, 2020).

Os algoritmos de aprendizado de máquina também podem ser implementados na busca por padrões que possam relacionar as características de determinada doença com o histórico do paciente, de forma a classificar os melhores tratamentos (Al-Hashimi; Hamdan, 2021). O auxílio de ferramentas de decisão ajuda os profissionais de saúde a estratificar os pacientes que demandam maior necessidade de atendimento personalizado. Podem utilizar modelos de inteligência artificial para modificar cronogramas de acompanhamento para pacientes individuais com risco significativo de exigir terapia adicional, bem como orientar discussões com famílias sobre resultados a longo prazo (Kwong *et al.*, 2022). No próximo tópico serão apresentadas as questões éticas envolvidas no uso da inteligência artificial.

### 3.6 ÉTICA E INTELIGÊNCIA ARTIFICIAL

Se tratando de uma área relativamente nova, ainda é cedo para estimar os impactos ocasionados pelas técnicas de inteligência artificial na área da saúde e na sociedade como um todo. Todavia, alguns pontos devem ser levados em consideração, principalmente a complexidade filosófica das implicações ocasionadas pela inteligência artificial. Tais como: uma vez que os modelos de inteligência artificial são treinados por humanos, quais medidas devem ser tomadas para que os preconceitos existentes na sociedade não sejam reproduzidos pelas máquinas, acentuando as desigualdades em saúde? A predição de futuras pandemias, de ocupação de leitos hospitalares, entre outros, pode contribuir para que os profissionais e gestores em saúde antecipem a mobilização de medidas de contenção, de recursos materiais e recursos humanos? A integração de dados em saúde de pacientes, por exemplo, número de passos diários, alterações na frequência cardíaca e horas de sono pode emitir alertas sobre a deterioração da condição de saúde que contribuam

para adoção de hábitos de vida mais saudáveis que neutralizem a evolução clínica da patologia?

Conforme mencionado anteriormente, as técnicas de inteligência artificial fornecem Suporte à Decisão Clínica, por meio de informações que subsidiam a tomada de decisão de profissionais e gestores em saúde. No entanto, dois pontos devem ser destacados aqui: 1) O profissional confia muito na classificação do modelo, mesmo quando ele está errado, desconsiderando a condição clínica do paciente e a experiência profissional – viés de automação. 2) Os profissionais estão fatigados pela emissão de grande número de alertas e, por este motivo, ignoram a classificação do modelo, mesmo quando não deveriam – viés de rejeição (Rajkomar *et al.*, 2018).

É importante ressaltar que esses modelos fazem uma previsão, calculam a probabilidade de determinado evento acontecer ou não, no entanto, não são mandatórios, os modelos fornecem um apoio a tomada de decisão, todavia, devem ser considerados outros elementos relacionados à história prévia dos pacientes, a condição de saúde, o serviço de saúde em nível local e a rede de assistência à saúde. Cabe aos profissionais de saúde colocar na balança para a tomada de decisão, nem acreditar fielmente nas decisões tomadas pelas máquinas, nem rejeitar totalmente. Nesse sentido, os profissionais levam vantagem em relação às máquinas, uma vez que estão posicionados à beira-leito do paciente e podem avaliar o estado geral em saúde.

Nesse sentido, algumas iniciativas foram lançadas que contribuem para a regularização do uso de dados e aplicação de técnicas de inteligência artificial na área da saúde. No Brasil, foi publicada a Lei 13.709/2018 – Lei Geral de Proteção de Dados (LGPD), entretanto, a maior parte do conteúdo entrou em vigor em setembro de 2020. De acordo com a LGPD os dados anonimizados não são considerados dados pessoais, a não ser que a anonimização possa ser revertida com esforços razoáveis. Outro trecho da Lei que está relacionado ao uso de inteligência artificial na área da saúde, refere-se à vedação da utilização de dados em saúde dos pacientes para seleção de riscos na contratação e/ou exclusão de planos pelas operadoras de planos privados de assistência à saúde (Brasil, 2018).

Além disso, são descritos na literatura documentos como: *pipeline* e *checklist*, os quais servem de guia aos pesquisadores e desenvolvedores na condução de pesquisas e desenvolvimento de produtos envolvendo inteligência artificial. O objetivo

é enquadrar as questões éticas dentro de todo o *pipeline* de atividades, iniciando pelo desenvolvimento, implementação e avaliação do modelo de aprendizado de máquina.

Pasternack (1992) em seu livro “Do caos à inteligência artificial” reuniu entrevistas, com cientistas da época, para responder a alguns questionamentos semelhantes. Quando a racionalidade científica se vê confrontada por sistemas dinâmicos e surge a necessidade de uma revolução epistemológica para a criação de um novo paradigma a partir dos conceitos de caos, complexidade, desordem organizada e auto-organização para então, propor uma explicação de ordem a partir do ruído (Pasternak, 1992).

Questionou se advento da tecnologia em nossa sociedade contribuiria para uma sociedade automatizada ou seria um instrumento de solidariedade social, contribuindo para uma sociedade mais eficaz e triunfante. Não houve um consenso sobre a inteligência artificial, alguns acreditavam no seu futuro, outros a tratavam como um entendimento matemático e sequencial da realidade, outros a relacionam a um modelo de funcionamento em paralelo e alguns consideravam-se céticos quanto a sua existência (Pasternak, 1992).

### 3.7 SISTEMAS COMPLEXOS

Com o intuito de auxiliar na compreensão da atuação da enfermagem em um contexto de uma doença infecciosa de dimensões pandêmicas, aliada a tecnologia, optou-se por utilizar, além dos referenciais teóricos de Enfermagem de Precisão e inteligência artificial, os sistemas complexos.

Os sistemas complexos surgem de uma evolução tecnológica, bastante presente no dia a dia das sociedades. São considerados fenômenos não lineares que a partir de condições iniciais podem ser modelados de forma precisa, permitindo o estabelecimento de medidas de complexidade para o estudo de possíveis regularidades, em fenômenos que antes eram considerados aleatórios. Os algoritmos computacionais auxiliam na evidência destes fenômenos (Piqueira; Oliveira, 2017).

O estudo dos sistemas complexos originou-se pelo matemático francês Henri Poincaré que por meio do estudo dos três corpos, mostrou que as equações diferenciais não lineares, dos sistemas determinísticos, podem comportar-se de forma sensível às condições iniciais, o que é considerado o fundamento do caos

determinístico. Além de Henri Poincaré, Claude E. Shannon e Allan M. Turing são autores importantes para os sistemas complexos, desenvolvendo a “Teoria da Informação” e os conceitos de computabilidade ou “Máquina de Turin”, respectivamente (Piqueira; Oliveira, 2017).

Turing, expressa o conceito de complexidade computacional do ponto de vista algorítmico, tanto que os computadores de hoje fundamentam-se no trabalho de Turin. Shannon, do ponto de vista informacional. Turing e Shannon trabalhavam simultaneamente, de forma independente, principalmente nas temáticas de comunicação e computação. As suas descobertas da época foram o marco inicial de recursos utilizados hoje na medicina, ciência, tecnologia e arte, as quais estão interessadas nas interações não lineares entre diversos agentes para imersão de fenômenos (Piqueira, 2016).

Uma medida objetiva de complexidade pode originar-se da teoria da informação e a associação destas definições caracterizam sistemas de computação, levando uma ideia de complexidade computacional. A complexidade computacional refere-se à quantidade de manipulações necessárias para a execução de um programa ou conjunto de algoritmos. Essas manipulações objetivam a resolução de um problema em linguagem matemática, portanto, os algoritmos são uma sequência de operações de aritmética e lógica. Sendo assim, a medida da complexidade computacional está relacionada a um programa que proporciona uma medida determinista da complexidade computacional (Piqueira, 2016).

Mas afinal, o que é complexidade? A complexidade é entendida como a associação de muitas partes ou de vários elementos e sua teoria ancora-se em uma lógica sistêmica, formada por cinco princípios, a saber:

O primeiro princípio da complexidade é a organização, já que é por meio da organização que os componentes de um sistema se inter-relacionam e, portanto, produzem a unidade complexa, culminando com a formação de um sistema. O holograma é o segundo princípio da complexidade, trata-se da observação das particularidades que formam o todo. No princípio hologramático a identidade é transferida de um olhar global para cada uma das suas partes. O terceiro princípio, é chamado de círculo retroativo e demonstra as relações causais entre causa e efeito, em que um age de forma dinâmica sobre o outro e se retroalimentam. Por este motivo é difícil identificar quem é o produtor ou o produzido, caracterizando o caráter não

linear da causa sobre o efeito e do efeito sobre a causa. O quarto princípio dos sistemas é a autoeco-organização, de acordo com este princípio o organismo vivo possui a capacidade de se auto-organizar, entretanto, sua autonomia é relativa, uma vez que é dependente do meio ambiente (eco). O quinto princípio é o diálogo e aborda a associação entre dois princípios que são indissociáveis e coexistem dentro de um sistema (Morin, 2015; Montezeli; Haddad; Peres; Matsuda, 2018).

A associação destes princípios aos conceitos de desordem, ordem, reorganização e interação constitui-se às raízes da complexidade que fundamentam as atividades desenvolvidas pelo homem (Morin, 2015; Montezeli; Haddad; Peres; Matsuda, 2018).

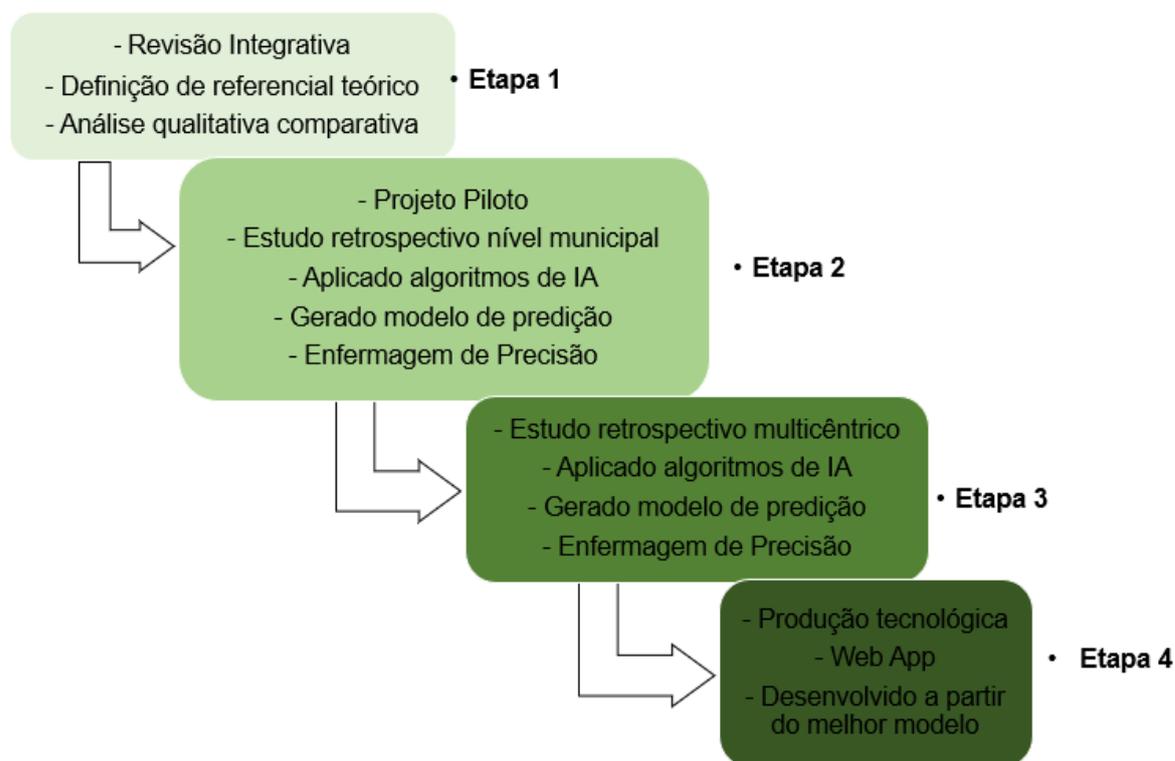
## 4 MÉTODO

Este estudo está inserido dentro do macroprojeto de pesquisa multicêntrica intitulado “Avaliação do cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros” o qual objetiva avaliar o cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros, distribuído em cinco dimensões principais, a saber: 1) Gestão hospitalar; 2) Liderança e gestão do cuidado; 3) Ambiente de prática profissional; 4) Experiência do paciente; e 5) Continuidade do cuidado. O projeto foi aprovado na Chamada MCTIC/CNPq/FNDCT/MS/SCTIE/Decit No 07/2020 - Pesquisas para enfrentamento da COVID-19, suas consequências e outras síndromes respiratórias agudas graves (Processo número: 402392/2020-5), e no edital de chamada pública no 005/2020 - adesão da FAPESC à chamada pública MCTIC/CNPq/FNDCT/MS/SCTIE/Decit N° 07/2020. O projeto teve Coordenação geral da professora Dra. Alacoque Lorenzini Erdmann e Dr. José Luís Guedes dos Santos.

Trata-se de uma pesquisa não experimental ou observacional. Nesse tipo de estudo o pesquisador descreve a ocorrência de um fenômeno e não interfere na variável independente. Caracterizado por um estudo retrospectivo com dimensão temporal transversal, em que as variáveis dependentes e independentes são coletadas em um determinado período, todavia, referem-se a eventos e comportamentos do passado. A principal vantagem das pesquisas transversais é o controle, entretanto não possibilita inferir tendências e mudanças ao longo do tempo (Polit; Beck, 2019).

Em virtude do objetivo desta pesquisa de desenvolver um modelo de inteligência artificial para predição da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, a partir do referencial teórico da Enfermagem de Precisão, houve a necessidade de utilizar-se de diferentes métodos de pesquisa para sua realização. O procedimento de construção do modelo de predição compreendeu quatro etapas, a saber: 1ª etapa ou revisão integrativa da literatura; 2ª etapa ou projeto piloto; 3ª etapa ou desenvolvimento do modelo de predição e 4ª etapa ou desenvolvimento de *Web App* como produção tecnológica. Na figura 4 abaixo estão representadas cada etapa e os respectivos métodos utilizados para o seu desenvolvimento.

Figura 6 - Etapas percorridas durante o estudo.



Fonte: Elaborado pela autora (2023).

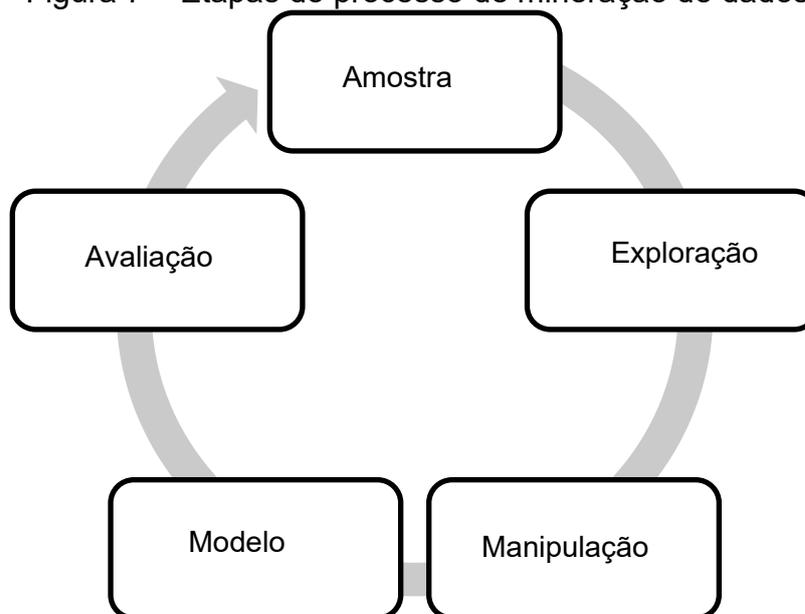
Cada uma das etapas da pesquisa originou um manuscrito. A primeira etapa originou o manuscrito 1) “Enfermagem de Precisão: Revisão integrativa da literatura” apresentado na seção 3.3 da fundamentação teórica. No capítulo dos resultados e discussão será apresentada o segundo manuscrito, proveniente da etapa 2) “Predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva na cidade de Florianópolis/SC”; o terceiro manuscrito da pesquisa, originado da etapa 3) “Predição de admissões na Unidade de Terapia Intensiva de pacientes com COVID-19 em cinco hospitais universitários do Brasil” e 4) “Modelo preditivo de inteligência artificial para internação em Unidade de Terapia Intensiva por COVID-19”.

Os procedimentos metodológicos empregados em cada etapa estão descritos de forma detalhada nos artigos. No entanto, cabe aqui uma descrição detalhada sobre a construção do modelo de aprendizado de máquina no que se refere à análise dos dados e a validação do modelo de predição.

#### 4.1 ANÁLISE DOS DADOS E MODELAGEM COM INTELIGÊNCIA ARTIFICIAL

Trata-se de uma pesquisa de análise de dados com técnicas de modelagem por IA, dividida em cinco etapas, que definem e exemplificam o processo de mineração de dados, conforme demonstrado na Figura 7 (Obenshain, 2004).

Figura 7 – Etapas do processo de mineração de dados.



Fonte: Adaptado de Obenshain (2004).

A primeira etapa refere-se ao banco de dados, com uma amostra representativa estatisticamente dos dados; em seguida inicia-se a exploração a partir de técnicas de visualização dos dados e técnicas estatísticas; na terceira etapa ocorre o ajuste dos dados para apresentação de variáveis quantitativas mais significativas; na quarta etapa evidencia-se o modelo para predição do desfecho primário e, finalmente ocorre a avaliação para confirmação da precisão de um dos modelos. As etapas do processo de mineração de dados são sequenciais, porém interativas, o que possibilita a movimentação para uma etapa anterior ou posterior (Obenshain, 2004).

O objetivo da mineração de dados é o tratamento dos dados coletados na origem, de forma a extrair relacionamentos que proporcionem informações acerca do objeto de estudo. A partir dos resultados, serão gerados modelos de decisão que melhor se ajustem aos dados, os quais serão avaliados por meio de métricas

específicas e por este motivo os modelos não serão definidos *a priori*. Alguns exemplos de modelos de decisão baseados em algoritmos de IA são: árvores de decisão, redes neurais, florestas aleatórias, *AdaBoost*, *Naive Bayes*, regressão logística, máquina de vetores de suporte.

Além disso, a matriz de correlação bidimensional será utilizada para demonstrar o coeficiente de correlação entre variáveis. A variável é registrada tanto na linha quanto na coluna da matriz e as intersecções apontam os coeficientes de correlação. O grau de relação entre duas variáveis pode ser descrito por métodos de correlação. Por meio do coeficiente de correlação é calculada a intensidade e a direção da relação e assim, indica o grau de “perfeição” entre a relação. O coeficiente de correlação varia de -1,00 a +1,00, correlações entre 0,00 e -1,00 expressam uma relação negativa entre as variáveis, enquanto coeficientes de correlação entre 0,00 e +1,00 expressam uma relação positiva. A interpretação entre correlação forte ou fraca depende das variáveis e do foco do estudo (Polit; Beck, 2019).

#### 4.2 VALIDADE DO MODELO DE PREDIÇÃO

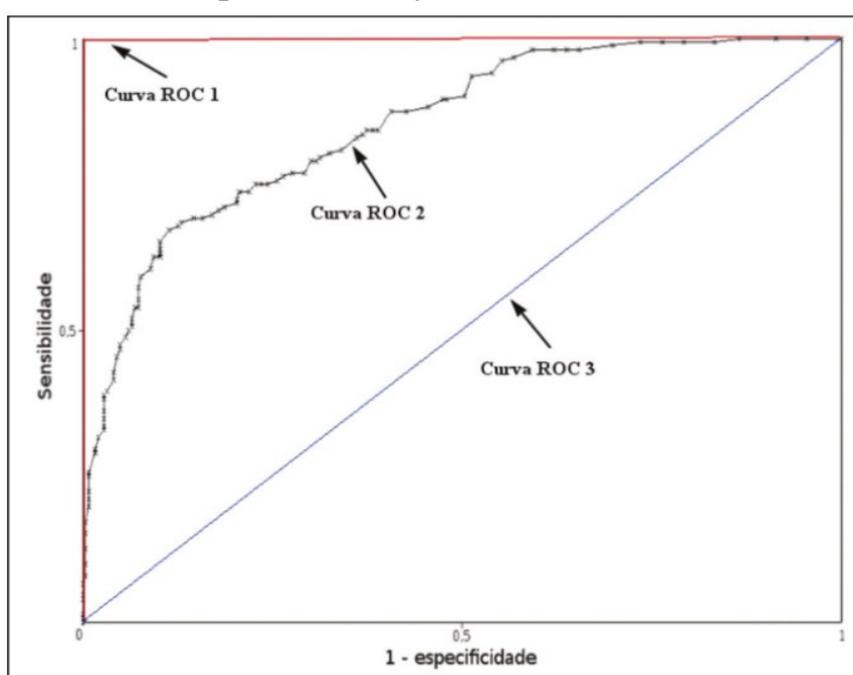
A validação cruzada, ou *cross validation*, é uma das técnicas aplicadas para a avaliação da precisão dos modelos de IA. A partir da amostra do estudo, o conjunto de dados é dividido aleatoriamente em partes iguais (*fold*), quatro partes do conjunto de indivíduos é utilizada para treinamento e uma parte para validação do modelo. Por exemplo, o desfecho de internação em UTI, ocasionado por um agravamento no quadro de um paciente infectado pela COVID-19 é predito a partir de um modelo específico, dividindo todo o banco de dados em 5 partes iguais, sendo utilizado 4 partes para o treinamento e 1 parte para a validação do modelo. O valor final da precisão é calculado a partir da média das interações dos cinco modelos gerados, um para cada porção do banco de dados (Werner *et al.*, 2020; Valerio Netto; Berton; Takahata, 2021).

A partir de então é observada a relação entre o desfecho predito e o desfecho observado em várias interações. A validação cruzada serve como uma ferramenta de validação da acurácia da predição de internação em UTI e mostra-se importante para validação do modelo ou mesmo para a comparação de diferentes modelos de previsão. Entretanto, são métricas específicas para a população em questão e as

acurácias de predição obtidas a partir da validação cruzada para determinado modelo não podem ser generalizadas a outros modelos (Werner *et al.*, 2020).

A avaliação da performance de predição do modelo de IA pode ser definida de acordo com algumas métricas dentre as várias existentes, atribuídas de acordo com o problema de estudo. Para este estudo, a principal métrica de avaliação do modelo é estipulada pela área sob a curva (*area under the curve – AUC*) de características de operação do receptor ROC (do inglês, *receiver operating characteristic*). O valor da *AUC* refere-se à área da região sob a curva ROC, a qual varia em uma escala de 0 a 1 e quanto mais próximo de 1, maior é a acurácia do modelo, conforme apresentado na Figura 8. A curva 1 apresenta uma boa performance, a curva 2 apresenta uma performance intermediária, enquanto a curva 3 ilustra um teste aleatório (Santos *et al.*, 2019; Hou *et al.*, 2021).

Figura 8 - Exemplos de curva ROC



Fonte: Santos *et al.* (2019).

O modelo de classificação pode errar ou acertar a sua predição, de acordo com o problema estudado, estas predições podem ser distribuídas em quatro classes possíveis (Valerio Netto; Berton; Takahata, 2021):

1) Verdadeiro Positivo (VP): quando o algoritmo classifica uma resposta como positiva e o dado, de fato, é positivo.

2) Verdadeiro Negativo (VN): quando o algoritmo classifica uma resposta como negativa e a resposta é mesmo negativa.

3) Falso Positivo (FP): o algoritmo classifica como positiva, mas na verdade a classe era negativa.

4) Falso Negativo (FN): é classificado como negativo pelo algoritmo, mas na verdade é positivo.

Estas informações geram a matriz de confusão, apresentada no Quadro 4, uma maneira de representar os resultados de classificação, ou seja, a quantidade de ocorrências classificadas pelo modelo de aprendizado de máquina em cada uma das quatro classes possíveis. Nesta representação é salutar o pesquisador atentar-se para os falsos positivos e falsos negativos, classes que indicam onde o modelo de predição está errando.

Quadro 4 - Matriz de confusão.

Matriz de confusão		Classe Predita	
		Negativa	Positiva
Classe Original	Negativa	VN	FP
	Positiva	FN	VP

Fonte: Elaborado pela autora (2023).

Além da *AUC*, a sensibilidade e a especificidade são outras duas métricas utilizadas para avaliação do modelo neste trabalho. A sensibilidade avalia a capacidade do modelo de detectar corretamente os resultados classificados como positivos. Por outro lado, a especificidade avalia a performance do modelo para identificação correta dos resultados negativos. As métricas são calculadas pelas equações 1 e 2 (Valerio Netto; Berton; Takahata, 2021)

$$(1) \quad \textit{sensibilidade} = \frac{VP}{VP + FN}$$

$$(2) \quad \textit{especificidade} = \frac{VN}{VN + FP}$$

### 4.3 ASPECTOS ÉTICOS

Em cumprimento à Resolução nº466/2012 e a Resolução 510/2016 do Conselho Nacional de Saúde que trata dos aspectos éticos da pesquisa com seres humanos, a pesquisa referente a etapa 3 desta tese foi aprovada pelo Comitê de Ética em Pesquisa com Seres Humanos (CEPSH) da UFSC CAAE 38912820.3.1001.0121 e parecer de aprovação número 4.347.463 e recebeu autorização institucional dos demais hospital universitário brasileiros envolvidos conforme parecer consubstanciado apresentado no Anexo A.

Os participantes foram convidados a participar da pesquisa e informados sobre os objetivos e a metodologia adotada no estudo. Também foi garantido que pudessem retirar o seu consentimento de participação em qualquer fase da pesquisa, sem nenhum prejuízo, através do Termo de Consentimento Livre e Esclarecido (TCLE), apresentado no Apêndice C. Assim, foi realizada a leitura do TCLE via ligação telefônica e antes do último parágrafo do termo iniciada a gravação, para que ficasse registrado em áudio o aceite do paciente em participar da pesquisa.

Para as etapas 1, 2 e 4 do estudo foram seguidas as recomendações éticas em pesquisa, no entanto, não necessitou de aprovação no Comitê de Ética em Pesquisa por tratar-se de banco de dados de domínio público (artigos e banco de dados disponíveis online). Na etapa 2 o banco de dados dos pacientes está anonimizado.

## 5 RESULTADOS E DISCUSSÕES

Este capítulo da tese foi descrito com os resultados obtidos nas etapas 2, 3 e 4 da pesquisa e serão apresentados no formato de manuscritos, conforme apresentados no Quadro 5.

Quadro 5 - Manuscritos resultantes da pesquisa de acordo com cada etapa do estudo.

Manuscrito	Etapa	Título
2	Projeto piloto	Predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva na cidade de Florianópolis/SC.
3	Estudo retrospectivo multicêntrico	Predição de admissões na Unidade de Terapia Intensiva de pacientes com COVID-19 em cinco hospitais universitários do Brasil.
4	Produção tecnológica	<i>Web App</i> para predição da internação em Unidade de Terapia Intensiva por COVID-19.

Fonte: Elaborado pela autora (2023).

### 5.1 ARTIGO 2 – PREDIÇÃO DA INTERNAÇÃO DE PACIENTES INFECTADOS PELA COVID-19 EM UNIDADE DE TERAPIA INTENSIVA NA CIDADE DE FLORIANÓPOLIS/SC

Como forma de divulgação parcial dos resultados a comunidade científica, o artigo descrito a seguir foi apresentado pela autora de forma online no Congresso Brasileiro de Informática em Saúde em 2021 e foi destaque entre os cinco melhores trabalhos apresentados no evento conforme apresentado no Anexo B. Além disso, foi submetido e está em processo de avaliação em um período da área de informática em saúde classificado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior no quadriênio de 2017-2020 como A4 para a área da enfermagem.

**Predição da internação de pacientes infectados pela COVID-19 em  
Unidade de Terapia Intensiva na cidade de Florianópolis/SC**

**Prediction of admission of COVID-19 infected patients to Intensive Care  
Unit in the city of Florianopolis/SC**

**Predicción del ingreso de pacientes infectados por COVID-19 em la  
Unidad de Cuidados Intensivos de la ciudad de Florianopolis/SC**

**Resumo.** O presente estudo objetivou aplicar e comparar algoritmos de aprendizado de máquina para predição da admissão de pacientes internados e contaminados pela COVID-19 em Unidade de Terapia Intensiva a partir do referencial teórico da Enfermagem de Precisão. Estudo retrospectivo das notificações do município de Florianópolis, realizado no período de março de 2020 a abril de 2021. Amostra composta por 180 pacientes, 90 deles passaram por Unidade de Terapia Intensiva e foram selecionados randomicamente mais 90 pacientes para equiparar os dados. Utilizou-se do *software Orange Data Mining* para exploração e análise dos dados. A performance dos algoritmos (rede neural, *adaboost*, regressão logística, floresta aleatória, *K Nearest Neighbor*, *Support Vector Machine*, Naive Bayes e árvore de decisão) foram validadas por meio da técnica de validação cruzada dos dados e as métricas de performance utilizadas foram sensibilidade, especificidade, área sob a curva (*AUC*) e matriz de confusão. O modelo apresentado pela rede neural, atinge melhor previsão para *AUC* (0.917), sensibilidade (0.861) e especificidade (0.825). A aplicação do modelo de aprendizado de máquina foi assertiva, ao predizer 155 dos 180 casos apresentados, dos quais 25 casos foram classificados entre falso positivo ou falso negativo.

**Palavras-chave:** Modelos de predição; Algoritmos; Inteligência artificial.

**Abstract.** This study aimed to apply and compare machine learning algorithms for predicting the admission of hospitalized patients contaminated by COVID-19 in Intensive Care Units based on the theoretical framework of Precision Nursing. Retrospective study of notifications from the city of Florianópolis, from March 2020 to April 2021. Sample composed of 180 patients, 90 of whom passed through the Intensive Care Unit and were randomly selected another 90 patients to match the data. Orange Data Mining software was used for data exploration and analysis. The performance of the algorithms (neural network, *adaboost*, logistic regression, random forest, *K Nearest Neighbor*, *Support Vector Machine*, Naive Bayes and decision tree) were validated through the technique of cross-validation of the data and the metrics of performance used were sensitivity, specificity, area under the curve (*AUC*) and confusion matrix. The model presented by the neural network, achieves better prediction for *AUC* (0.917), sensitivity (0.861) and specificity (0.825). The application of the machine learning model was assertive in predicting 155 of the 180 cases presented, where 25 cases were classified between false positive or false negative.

**Keywords:** Modelos de predição; Algorithms; Artificial Intelligence.

**Resumen.** Este estudio tuvo como objetivo aplicar y comparar algoritmos de aprendizaje automático para predecir el ingreso de pacientes hospitalizados contaminados por COVID-19 en las Unidades de Cuidados Intensivos basándose en el marco teórico de la Enfermería de Precisión. Estudio retrospectivo de las notificaciones de la ciudad de Florianópolis, de marzo de 2020 a abril de 2021. Muestra compuesta por 180 pacientes, de los cuales 90 pasaron por la Unidad de Cuidados Intensivos y se seleccionaron aleatoriamente otros 90 pacientes para cotejar los datos. Para la exploración y el análisis de los datos se utilizó el software Orange Data Mining. El rendimiento de los algoritmos (red neuronal, adaboost, regresión logística, bosque aleatorio, *K Nearest Neighbor*, *Support Vector Machine*, Naive Bayes y árbol de decisión) se validó mediante la técnica de validación cruzada de los datos y las métricas de rendimiento utilizadas fueron sensibilidad, especificidad, área bajo la curva (*AUC*) y matriz de confusión. El modelo presentado por la red neuronal, logra una mejor predicción para el *AUC* (0,917), la sensibilidad (0,861) y la especificidad (0,825). La aplicación del modelo de aprendizaje automático fue asertiva en la predicción de 155 de los 180 casos presentados, donde 25 casos fueron clasificados entre falsos positivos o falsos negativos.

**Palabras clave:** Modelos de predição; Algoritmos; Inteligencia Artificial.

## INTRODUÇÃO

Os pacientes infectados pela COVID-19 apresentam uma evolução clínica rápida para piora da situação de saúde, levando à sepse, necessidade de internação em Unidade de Terapia Intensiva (UTI) e morte. A hospitalização ocorre de 20 a 30% dos casos que desenvolvem a forma moderada a grave da doença, e destes, de 5 a 12% necessitam de cuidados em UTI (Cheng *et al.*, 2020). Assim, quando ocorre um aumento no número de casos de COVID-19, aumenta a demanda por recursos hospitalares como leitos de UTI e ventiladores mecânicos, o que exige a rápida mobilização de recursos materiais e humanos, sobretudo a rápida tomada de decisões (Amer *et al.*, 2021; Hou *et al.*, 2021).

A análise preditiva de precisão pode auxiliar em decisões clínicas complexas, as quais convergem para a identificação precoce de pacientes com risco de agravamento no quadro clínico (Subudhi *et al.*, 2021). Os modelos de decisão, criados a partir de algoritmos de aprendizado de máquina, mostram-se úteis diante de um cenário de uma crise sanitária mundial, uma vez que, são capazes de analisar uma grande quantidade de dados, aprender sobre a relação entre estes dados e extrair *insights* (Magunia *et al.*, 2021). O conhecimento dos padrões de relacionamentos

entre os biomarcadores em relação a determinado desfecho, neste caso a internação em UTI, fornece subsídios de apoio à tomada de decisão de gestores e profissionais de saúde (Cheng *et al.*, 2021; Cuocolo *et al.*, 2020a).

Durante a pandemia, por exemplo, aplicações de inteligência artificial foram empregadas para entender o padrão de disseminação viral; diagnóstico médico por imagens, como exames de raio-X, ensaio de detecção de COVID-19 baseado em *Clustered Regularly Interspaced Short Palindromic Repeats* (CRISPR); classificação taxonômica de genomas de COVID-19; aplicativos de smartphones para monitoramento e avaliação de risco da COVID-19; desenvolver novas abordagens terapêuticas eficazes; classificação do melhor tratamento; previsão de sobrevivência em pacientes graves acometidos pela COVID-19; dentre outras aplicações (Al-Hashimi; Hamdan, 2021; Alimadadi *et al.*, 2020).

O levantamento inicial de que idosos são considerados grupo de risco para a COVID-19 aos poucos foi questionado, ao passo que adultos jovens começaram a sofrer sintomas graves da doença. O que indica que a classificação e categorização do risco da doença, deve considerar características fisiológicas e genéticas personalizadas dos indivíduos (Lopes Júnior, 2021a), uma vez que se acredita haver uma possível predisposição genética à infecção por COVID-19. Os algoritmos de aprendizado de máquina preveem os pacientes com maior vulnerabilidade ou resistência a uma possível infecção por COVID-19, contribuindo para o aumento da precisão e a rapidez do diagnóstico (Alimadadi *et al.*, 2020).

Nesse sentido de busca pela personalização dos cuidados em saúde, voltados para intervenções mais assertivas em saúde, surge o termo “precisão” como sinônimo de personalização dos cuidados em saúde (Lopes Júnior, 2021b). A associação deste conhecimento aos modelos de prática clínica de enfermagem abre caminho para uma nova era da Enfermagem de Precisão, tendo como premissa a fundamentação do cuidado de enfermagem baseada nas necessidades do indivíduo (Yuan, 2015; Lopes Júnior, 2021b).

Durante o Processo de Enfermagem (PE), é coletado o histórico do paciente, incluindo variáveis clínicas, ambientais e comportamentais de pacientes. Também é avaliado pelos enfermeiros a condição clínica do paciente naquele momento, por meio de sinais vitais e exame físico. A integração desses dados, associada à capacidade

de análise em larga escala fornecem inteligência que suportam intervenções mais assertivas no cuidado em enfermagem (Yuan, 2015).

Diante do exposto, o presente estudo fundamentou-se nas seguintes questões de pesquisa:

- Quais são as variáveis preditoras da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva segundo os fundamentos teóricos da Enfermagem de Precisão?

- Qual é o modelo de inteligência artificial que apresenta a melhor performance para predição da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva?

E, objetivou aplicar e comparar algoritmos de aprendizado de máquina para predição da admissão de pacientes internados e contaminados pela COVID-19 em Unidade de Terapia Intensiva a partir do referencial teórico da Enfermagem de Precisão.

## **MATERIAIS E MÉTODOS**

### TIPO DE ESTUDO

Realizou-se um estudo retrospectivo das notificações de pacientes infectados pela COVID-19 no município de Florianópolis, localizado na região Sul do Brasil. No Brasil, todos os pacientes que apresentam sintomas gripais devem ser notificados para investigação e posterior encerramento da ficha de notificação a partir do caso confirmado via exame ou excluído, quando o exame é negativo.

### COLETA DE DADOS

Os dados foram coletados no site “covidômetro”, no mês de abril de 2021 e abrangeu as notificações de COVID-19 de oito de março de 2020 a 20 de abril de 2021. O site foi estabelecido pela cidade em 2020 e o banco de dados associado ao site refere-se à vigilância municipal para monitoramento das infecções por COVID-19 notificados no município (Florianópolis, 2023).

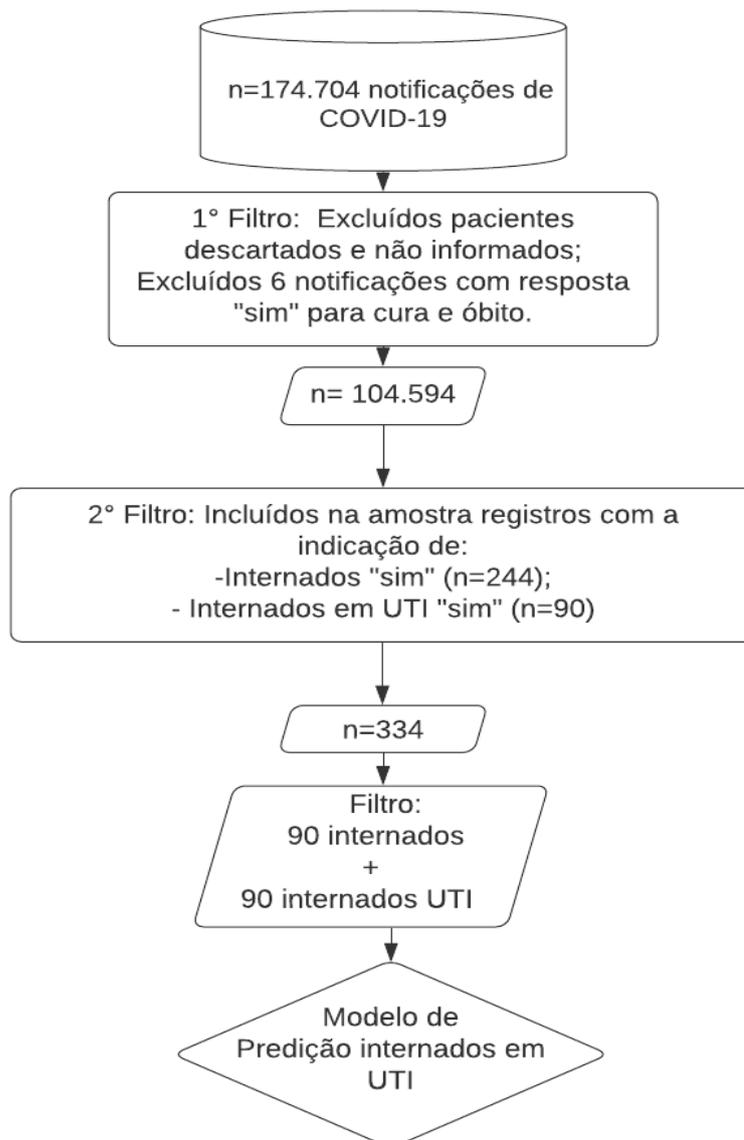
O site é composto por informações sobre a COVID-19, tais como: mapa de risco, número de leitos de enfermagem ocupados e livres, taxa de ocupação das Unidades de Terapia Intensiva (UTIs), casos suspeitos, casos confirmados, número de óbito, entre outros. Estas informações fornecem critérios objetivos para avaliação sistemática sobre a necessidade de medidas não farmacológicas mais restritivas ou mais permissivas no município. Também dispõe informações contidas no Plano Nacional de Operacionalização da Vacinação contra Covid-19, como: população alvo, comorbidades estabelecidas para vacinação e número de vacinados (Florianópolis, 2023).

## POPULAÇÃO E AMOSTRA

A população da pesquisa foi composta por 174.704 pacientes notificados com COVID-19. Embora os pacientes fossem notificados no município de Florianópolis, vale ressaltar que nem todos os infectados residiam na cidade. Como o banco de dados trata-se de notificações de COVID-19, foram aplicados os critérios de exclusão para remover da amostra os casos que haviam sido descartados como não reagente a COVID-19 ou não informaram a confirmação da notificação, isto é, os casos foram descartados após resultado de exames e as notificações não foram confirmadas. Além disso, foram excluídas da amostra seis notificações com resposta “sim” para cura e óbito na mesma ficha de investigação. As informações contidas na ficha de notificação identificam a situação clínica do paciente naquele momento e optou-se por considerar as situações em que os pacientes já haviam obtido um desfecho. Portanto, foram considerados os desfechos primários, ou variável alvo de interesse: admissão na UTI em comparação com admissão geral em hospital.

Após aplicados os critérios de inclusão e exclusão do estudo restaram 90 pacientes que haviam sido internados em Unidade de Terapia Intensiva (UTI) e foram selecionados randomicamente mais 90 pacientes que passaram por internação hospitalar para manter o equilíbrio dos dados para modelagem. Desta forma, a amostra do estudo foi composta por 180 pacientes, conforme apresentado na Figura 9.

Figura 9 - Fluxograma de seleção de pacientes e mineração dos dados.

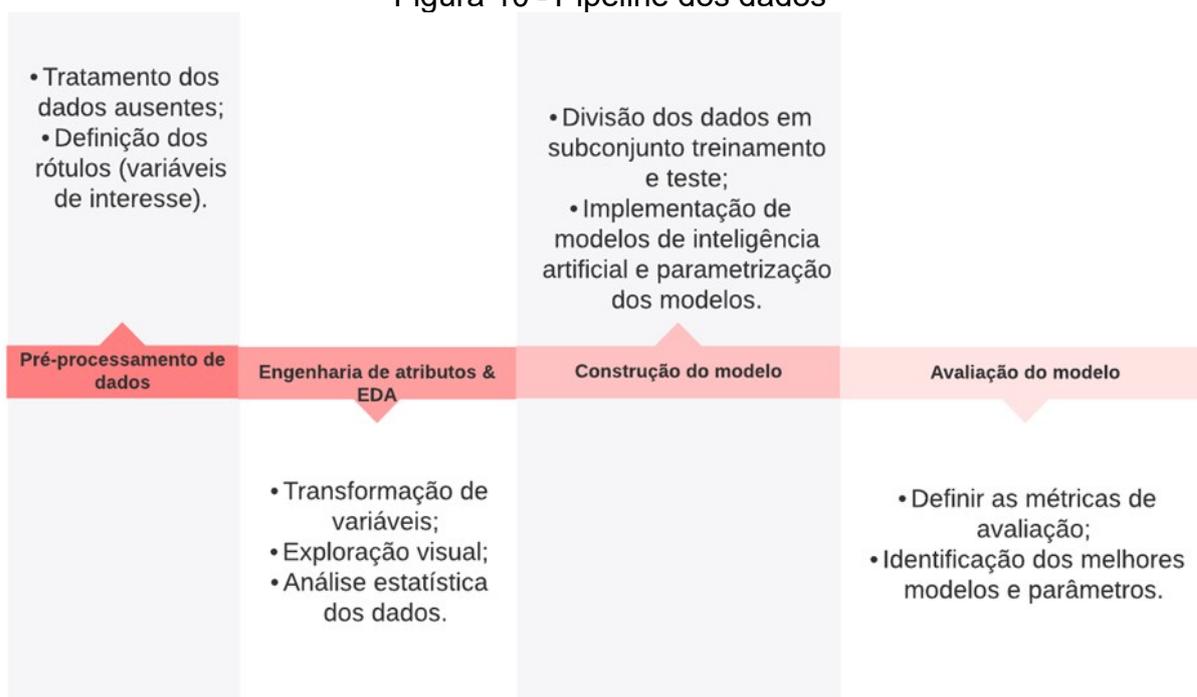


Fonte: Elaborado pela autora (2023).

## CONSTRUÇÃO DO MODELO DE APRENDIZADO DE MÁQUINA

Foram percorridas quatro etapas para a construção do modelo, a saber: pré-processamento de dados, engenharia de atributos, construção do modelo e avaliação do modelo, conforme demonstrado na Figura 10.

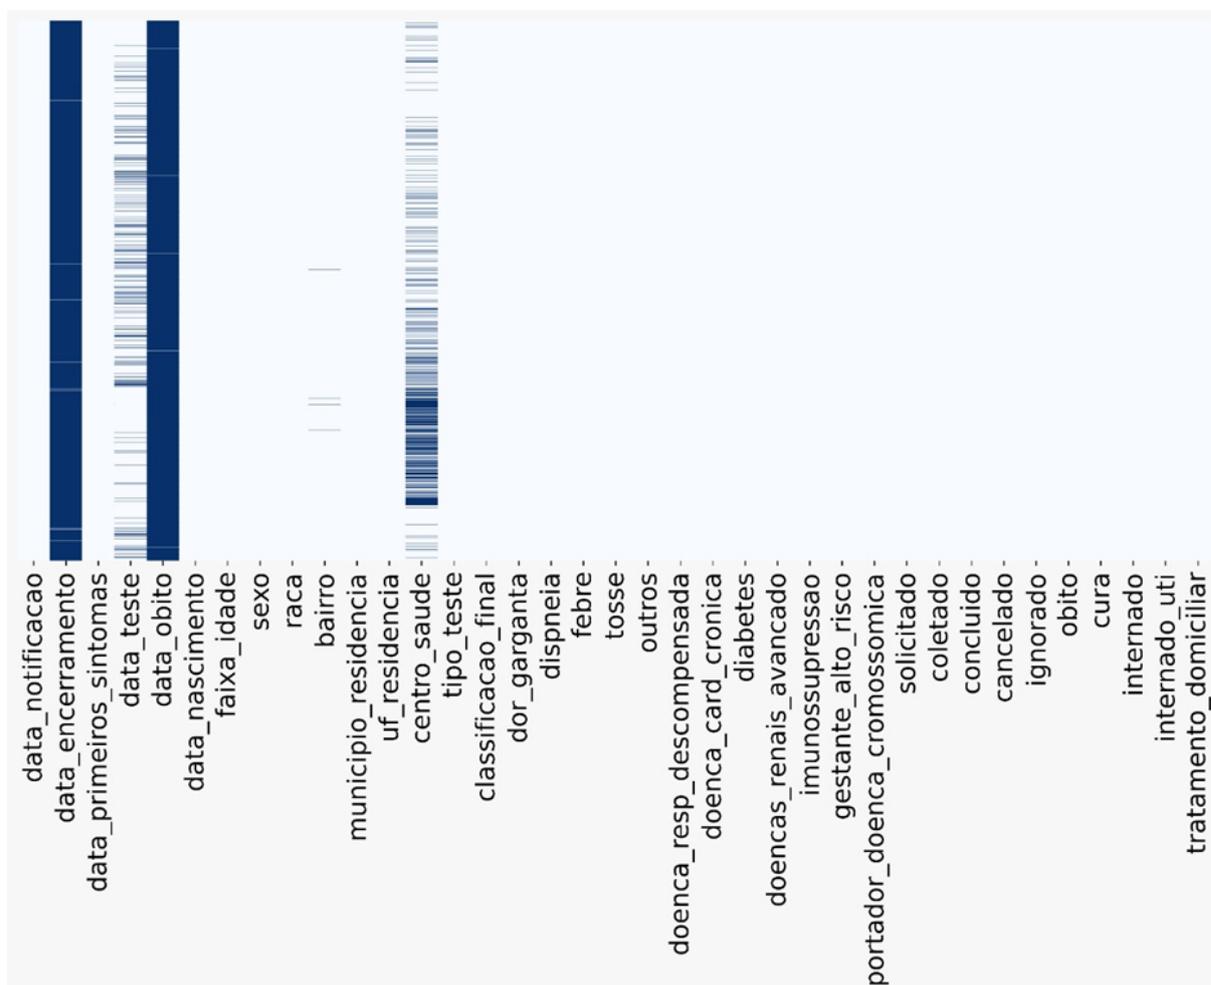
Figura 10 - Pipeline dos dados



Fonte: Elaborado pela autora (2023).

Na fase de pré-processamento de dados observou-se os valores ausentes, no banco de dados, para cada uma das variáveis consideradas na ficha de notificação. Em uma escala de cores que varia de azul claro a azul escuro, representada na Figura 11. Os traçados na cor azul escuro demonstram as variáveis com maior número de dados ausentes, são elas: data de encerramento da ficha de notificação, data de óbito, centro de saúde, data de realização do teste e bairro. Enquanto as variáveis na cor azul claro não apresentam dados faltantes. Para a análise, as variáveis com dados ausentes não eram relevantes para a modelagem e, portanto, foram retiradas da amostra.

Figura 11 - Representação de dados ausentes.



Fonte: Elaborado pela autora (2023).

A partir da seleção das variáveis de entrada e associação aos elementos da Enfermagem de Precisão, foram incluídas as variáveis correspondentes a fenótipo, genótipo e biomarcadores, descritas a seguir:

Dentre as variáveis correspondentes a fenótipo (informações demográficas) foram consideradas as seguintes variáveis: faixa etária em anos, distribuídas em 10 categorias (até 9 anos, 10 a 19 anos, 20 a 29 anos, 30 a 39 anos, 40 a 49 anos, 50 a 59 anos, 60 a 69 anos, 70 a 79 anos, 80 a 89, acima de 90), sexo (feminino e masculino); raça (amarela, branca, parda, preta). No que se refere a fenótipo (comorbidades e gestação): doença respiratória descompensada; doença cardíaca crônica; diabetes; doença renal em estágio avançado; imunossupressão; gestante de alto risco. A doença cromossômica foi a variável relacionada ao genótipo. Em relação aos biomarcadores foram considerados sinais e sintomas, tais como: dor de garganta;

dispneia; febre e tosse. Além disso, foram consideradas as variáveis internação e internação em UTI como desfechos primários. Não foram avaliadas variáveis correspondentes a epigenética. Os dados originais consistem em variáveis do tipo categóricas, as variáveis faixa etária e raça, categorizadas em mais de dois valores e as demais variáveis categorizadas em sim ou não.

Para a criação do modelo de inteligência artificial torna-se necessário a transformação destas categorias para valores numéricos. A transformação dos dados ocorre por técnica chama “*One-hot Encoding*”, onde cada variável é transformada em uma variável binária (zero ou um), ou seja, para variáveis categóricas com mais de dois valores, realiza-se a criação de uma entrada para o modelo de cada valor possível da variável, assim, para o caso de faixa etária, cada faixa de idade torna-se uma entrada, categorizada em um quando a informação corresponde aquele paciente e categorizada em zero quando aquele dado não está relacionado ao paciente. Este processo de binarização das variáveis por “*One-hot Encoding*”, torna-se necessário para a modelagem de valores igualmente importantes, uma vez que um paciente, por exemplo, de um sexo não possui prevalência sobre o outro grupo, assim como todas as demais variáveis de entrada do modelo.

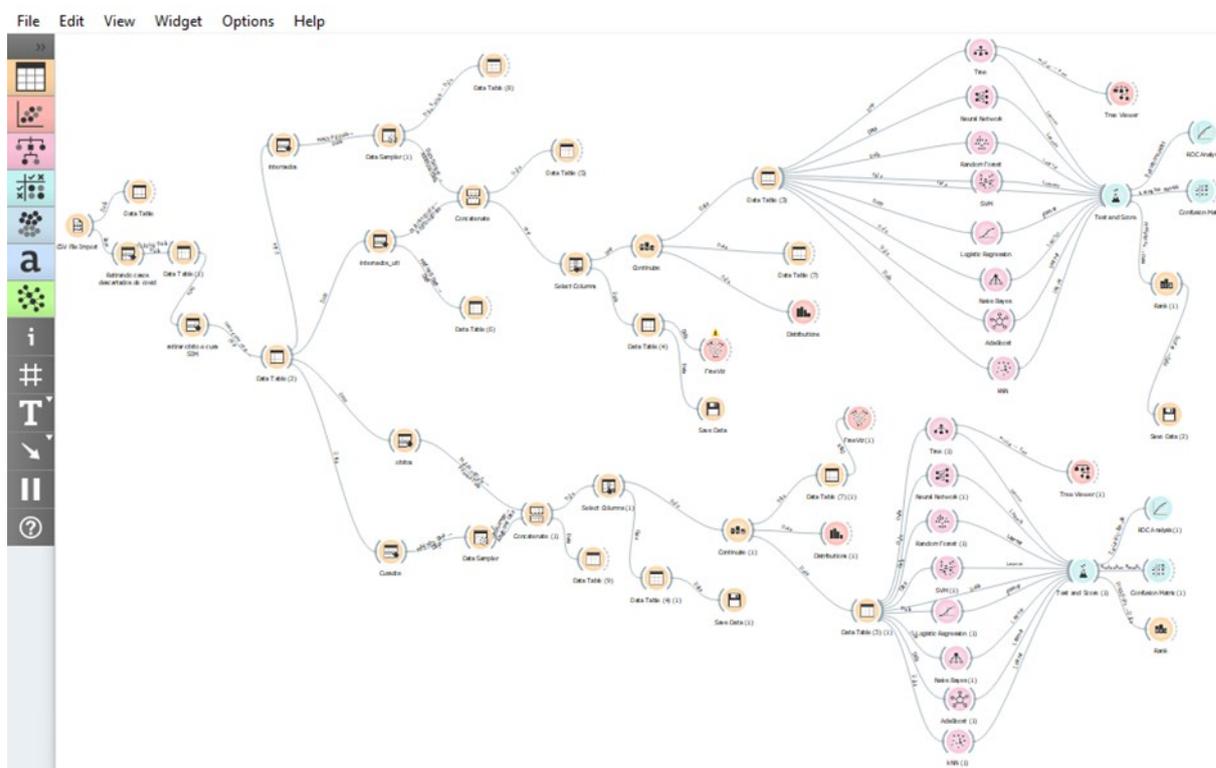
Todas as variáveis foram transformadas em valores numéricos e implementada a modelagem dos dados utilizando dos algoritmos: rede neural, *adaboost*, regressão logística, floresta aleatória, *kNN*, *Naive Bayes*, *SVM* e árvore de decisão. A parametrização dos modelos decorreu de um processo iterativo, selecionando os algoritmos de melhor desempenho, de acordo com as métricas de avaliação.

## ANÁLISE DE DADOS E VALIDAÇÃO DO MODELO

O desenvolvimento do trabalho foi realizado prioritariamente no *software* de código aberto denominado *Orange Data Mining* (Figura 12), com implementações em linguagem de programação e exploração visual dos dados no *Python*. A análise exploratória, por meio da apresentação visual dos dados no formato de gráficos, foi realizada no *software* Power BI, apresentando a caracterização dos participantes do estudo para cada uma das variáveis do estudo. Os modelos foram validados por meio

de técnicas de validação cruzada dos dados, observando as métricas de área acima da curva, sensibilidade, especificidade e matriz de confusão.

Figura 12 - Análise de dados realizada no *software Orange Data Mining*.



Fonte: Elaborado pela autora (2023).

## ASPECTOS ÉTICOS

O banco de dados utilizado no estudo, refere-se a dados de domínio público, anonimizados, sem constar informações que possibilitaram a identificação dos pacientes. Portanto, exclui a necessidade da pesquisa passar por aprovação de comitê de ética em pesquisa com seres humanos.

## RESULTADOS E DISCUSSÃO

Dos pacientes internados em leito hospitalar e internados em UTI, 56,11% eram do sexo masculino, 158 pacientes (87,77%) de raça branca e a maioria dos pacientes, 45 (25%) tinha idade entre 50 a 59 anos. Dentre os sintomas mais comuns, 95 pacientes (52%) apresentaram tosse, 93 pacientes (52%) apresentaram febre e 76

pacientes (42%) apresentaram dispneia. Da mesma forma, as comorbidades mais frequentes entre os pacientes foram: doença cardíaca (n= 20, 11,11%), diabetes (n= 19, 10,56%) e doença respiratória (n= 8, 4,44%). As demais variáveis também são mostradas na Tabela 1.

Tabela 1 - Dados demográficos basais e dados clínicos dos pacientes do estudo no momento de preenchimento da ficha de notificação.

<b>Variáveis (n=180)</b>	<b>n (%)</b>
<b>Sexo</b>	
Masculino	101 (56,11)
Feminino	79 (43,89)
<b>Faixa etária</b>	
50 a 59 anos	45 (25)
60 a 69 anos	32 (17,7)
40 a 49 anos	29 (16,11)
70 a 79 anos	25 (13,88)
30 a 39 anos	20 (11,11)
80 a 89 anos	14 (7,77)
20 a 29 anos	8 (4,44)
Menos de 19 anos	4 (2,22)
Mais de 90 anos	3 (1,66)
<b>Raça</b>	
Branca	158 (87,77)
Preta	13 (7,22)
Amarela	7 (3,88)
Parda	2 (1,11)
<b>Sinais e Sintomas</b>	
Tosse	95 (52)
Febre	93 (52)
Dispneia	76 (42)
Dor de garganta	24 (13)
<b>Comorbidades</b>	
Doença cardíaca	20 (11,11)
Diabetes	19 (10,56)
Doença respiratória	8 (4,44)
Imunossupressão	2 (1,11)
Doença renal	1 (0,56%)
Doença cromossômica	1 (0,56%)
<b>Gestação de alto risco</b>	1 (0,56%)

Fonte: Elaborado pela autora (2023).

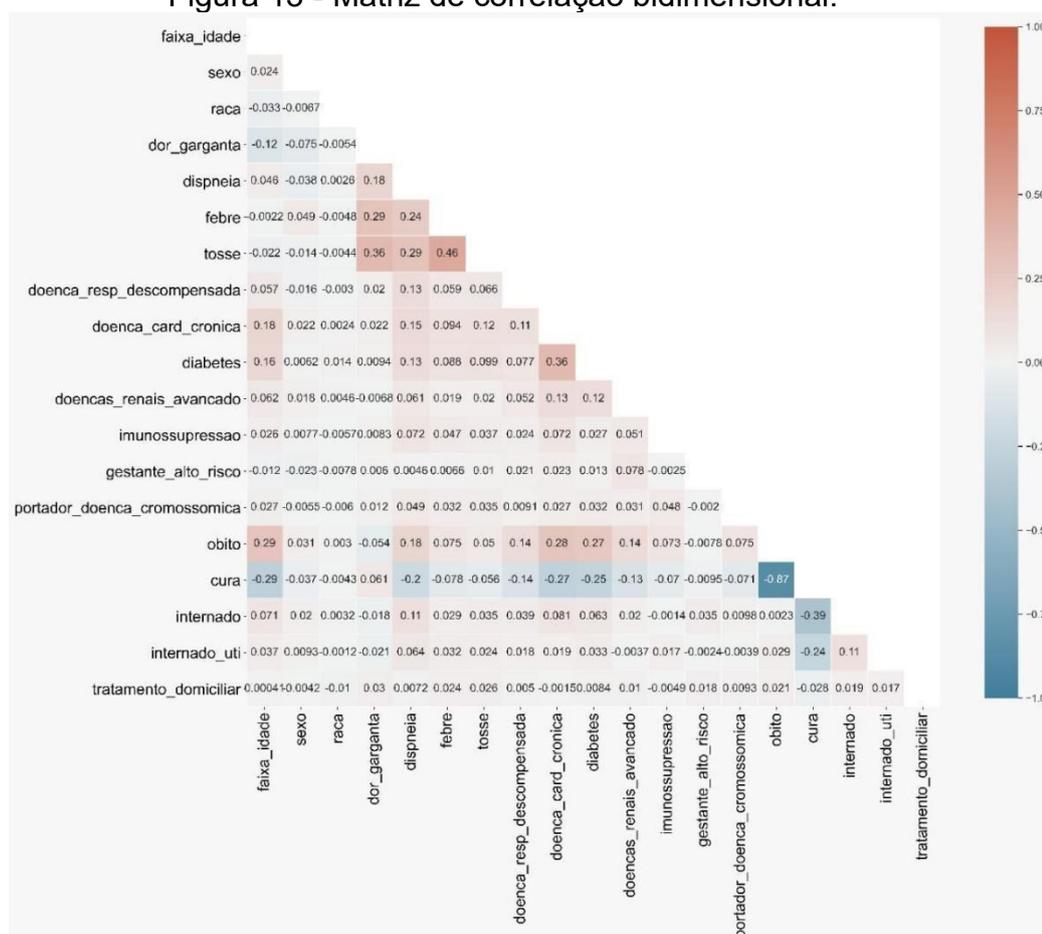
Estudo anterior realizado com 10.504 pacientes positivos para COVID-19 e admitidos em UTI, também identificou os sintomas de tosse (n= 5181, 49,7%), febre

(n= 4849, 46,5%) e dispneia (n= 3246, 31,1%) sendo os mais frequentes para esses pacientes. No que se refere às comorbidades, diabetes (n=1613, 15,5%) foi a mais recorrente, seguida de obesidade (n= 917, 8,8%) e doença respiratória crônica (n= 883, 8,5%) (Izquierdo; Ancochea; Soriano, 2020). A diabetes e a doença respiratória também estão entre as comorbidades mais prevalentes do presente estudo, entretanto, enquanto as doenças cardíacas aparecem como a comorbidade mais prevalente do corrente estudo, na literatura é evidenciada em quarto lugar, após diabetes, obesidade e doença respiratória crônica (Izquierdo; Ancochea; Soriano, 2020). A variável obesidade mencionada na literatura, não foi avaliada no presente estudo.

A matriz de correlação bidimensional é demonstrada na Figura 13 para evidenciar o coeficiente de correlação entre as variáveis, onde é possível observar as correlações positivas e negativas entre variáveis, em que tosse e febre apresentaram a maior correlação positiva (0,46); seguida de diabetes e doença cardíaca crônica (0,36); tosse e dor de garganta (0,36); óbito e faixa de idade (0,29); febre e dor de garganta (0,29); tosse e dispneia (0,29); óbito e doença cardíaca crônica (0,28); óbito e diabetes (0,27); febre e dispneia (0,24); óbito e dispneia (0,18); doença cardíaca crônica e faixa etária (0,18); dispneia e dor de garganta (0,18) e assim por diante.

Entre as variáveis que apresentaram correlação negativa estão: cura e óbito (-0,87); seguida de internação e cura (-0,39); cura e faixa etária (-0,29); cura e doença cardíaca crônica (-0,27); cura e diabetes (-0,25); internação em UTI e cura (-0,24); cura e dispneia (-0,20); cura e doença respiratória descompensada (-0,14); cura e doenças renais em estágio avançado (-0,13); cura e imunossupressão (-0,07); e assim segue.

Figura 13 - Matriz de correlação bidimensional.



Fonte: Elaborado pela autora (2023).

As variáveis preditoras de internação em UTI com maior impacto nas previsões do modelo, de acordo com a apresentação na Tabela 2, incluíram internação hospitalar, raça e dor de garganta, ranqueadas pelo índice de impureza de Gini (Kwong *et al.*, 2022). Optou-se por manter internação hospitalar como uma variável preditora de internação em UTI, uma vez que, não apenas os pacientes internados precisam de cuidados em um leito de UTI. Muitos pacientes não internados em leito clínico, chegavam para atendimento hospitalar, tendo como porta de entrada o Serviço de Atendimento Móvel de Urgência (SAMU) e/ou a emergência dos hospitais já apresentando condições clínicas de necessidade de atendimento em leitos de UTI.

Tabela 2 - Ranking das variáveis.

<b>Variável</b>	<b>Gini decrease</b>
Internação	0.263
Raça	0.019
Dor de garganta	0.010
Febre	0.005
Faixa etária	0.005
Imunossupressão	0.004
Doença cromossômica	0.003
Gestante de alto risco	0.003
Doenças renais em estágio avançado	0.003
Doença cardíaca crônica	0.003
Dispneia	0.001

Fonte: Elaborado pela autora (2023).

Em relação ao resultado obtido pela variável preditora raça, não pode ser generalizado, uma vez que, a amostra não foi representativa da população, havia 158 pacientes (87,77%) de raça branca. O tamanho da amostra também apresenta algumas limitações relacionadas à variável gestação de alto risco, embora tenha sido considerada no estudo, não mostrou-se influente no modelo.

As variáveis preditoras identificadas no presente estudo, diferem de achados anteriores identificados na literatura. De acordo com Izquierdo, Ancochea, Soriano (2020) a idade, temperatura e taquipneia apresentaram-se como as variáveis preditoras mais parcimoniosas para admissão de pacientes em UTI (Izquierdo; Ancochea; Soriano, 2020). Já Fu-Yan descreve a insuficiência respiratória, choque, inflamação e insuficiência renal como as variáveis preditoras de maior risco para transferência de pacientes para UTI (Cheng *et al.*, 2020). Os estudos avaliam diferentes biomarcadores, ou seja, nem sempre as mesmas variáveis preditoras de internação em UTI foram analisadas em cada um dos estudos, o que confere especificidades únicas para as pesquisas.

Com o avanço da vacinação contra COVID-19, por exemplo, a situação vacinal dos pacientes seria um biomarcador interessante a ser analisado quanto a sua capacidade preditora de internação em UTI. Estudo preliminar indica uma redução

acentuada nos casos graves de COVID-19 após a vacinação, chegando a 65,6% a redução de pacientes vacinados internados em UTI. Esses números podem sofrer algumas variações de acordo com o imunobiológico aplicado e o intervalo de tempo de aplicação; taxas de cobertura vacinal; realização do esquema vacinal completo e dose de reforço (Moghadas *et al.*, 2020).

Os pacientes com mais de uma comorbidade totalmente vacinados tinham 48,8% menos probabilidade de serem admitidos na UTI, 55,4% menos probabilidade de usar ventiladores mecânicos e 22,6% menor probabilidade de morrer. Além disso, eles foram hospitalizados por períodos significativamente mais curtos, enquanto os pacientes não vacinados ficaram ausentes do trabalho por períodos mais longos em comparação com os pacientes parcial ou totalmente vacinados (Maltezou *et al.*, 2023).

As variáveis preditoras da internação de pacientes infectados pela COVID-19 em UTI foram relacionadas a biomarcadores de sinais e sintomas e a determinadas comorbidades, que compõem o histórico prévio dos pacientes. Esta identificação dos mecanismos biológicos subjacentes que precedem os casos graves de COVID-19 é o campo de atuação da enfermagem. Assim, o conhecimento das variáveis preditoras pode auxiliar à prática clínica dos enfermeiros auxiliando no raciocínio clínico e na tomada de decisão, em um contexto que exige uma decisão rápida e ao mesmo tempo fundamentada (Corwin; Ferranti, 2016).

A associação de biomarcadores à doença, possibilita a identificação de alterações na homeostase do organismo. A Enfermagem de Precisão compreende justamente a identificação dos melhores preditores para a COVID-19, tarefa associada a capacidade de análise de dados centrada na inteligência artificial, e a partir disso planejar intervenções de enfermagem que podem beneficiar o paciente (Corwin; Ferranti, 2016; Fu *et al.*, 2020).

A Enfermagem de Precisão pode ser definida como a ampla compreensão do meio ao qual um indivíduo está inserido, seus hábitos de vida, doenças prévias, sinais e sintomas e a partir desta identificação, o planejamento de intervenções alinhadas às necessidades individuais de cada paciente (Yuan, 2015; Corwin; Ferranti, 2016). Portanto, a Enfermagem de Precisão está alinhada ao Processo de Enfermagem e pode ser aplicada em cada uma das suas etapas: coleta de dados de Enfermagem, diagnóstico de Enfermagem, Planejamento de Enfermagem, Implementação e Avaliação de Enfermagem.

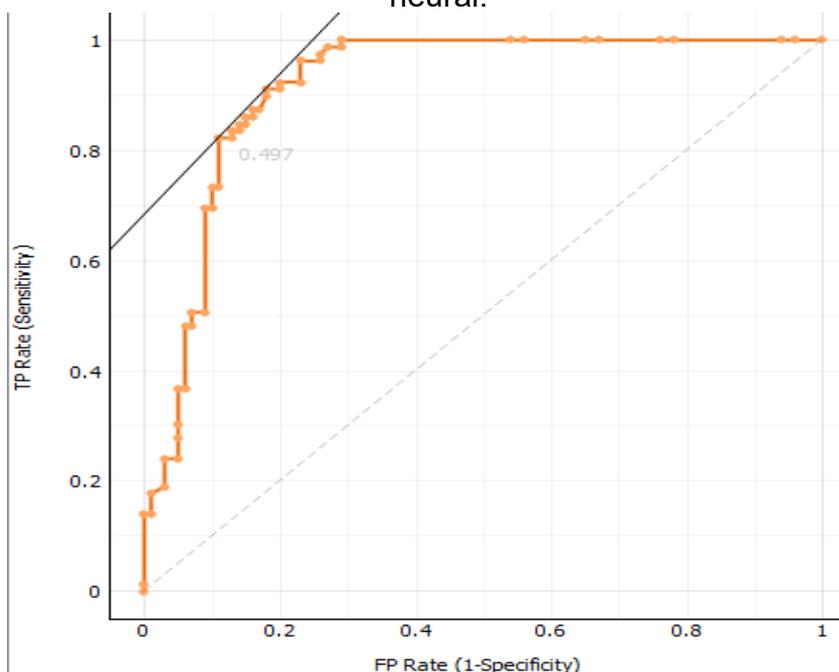
O desempenho do modelo de predição de internação em UTI é apresentado na Tabela 3. A *AUC* do modelo de internação em UTI variou de 0.857 a 0.917, sendo que a rede neural alcançou a melhor previsão de acordo com a *AUC*, a ROC pode ser observada na Figura 14 e a matriz de confusão na Figura 15.

Tabela 3 - Desempenho dos algoritmos.

Algoritmos	<i>AUC</i>	Sensibilidade	Especificidade
Rede neural	0.917	0.861	0.825
<i>AdaBoost</i>	0.911	0.822	0.800
Regressão Logística	0.911	0.806	0.862
Floresta aleatória	0.896	0.828	0.850
<i>kNN</i>	0.893	0.806	0.750
<i>Naive Bayes</i>	0.886	0.833	0.962
SVM	0.875	0.817	0.850
Árvore de decisão	0.857	0.811	0.925

Fonte: Elaborado pela autora (2023).

Figura 14 - Característica de Operação do Receptor (ROC) para o modelo de rede neural.



Fonte: Elaborado pela autora (2023).

Figura 15 - Matriz de confusão para o modelo de rede neural.

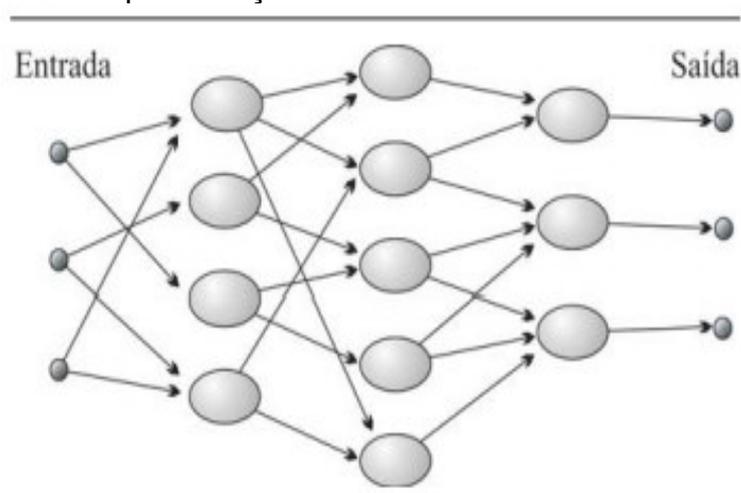
		Predicted		$\Sigma$
		NÃO	SIM	
Actual	NÃO	66	14	80
	SIM	11	89	100
$\Sigma$		77	103	180

Fonte: Elaborado pela autora (2023).

A rede neural artificial *multilayer perceptron* (MLP) foi o modelo que obteve a melhor performance para predição da internação de pacientes COVID-19 em UTI. Parametrizada em 50, 200, 350 neurônios nas camadas ocultas, a função de ativação utilizada foi a *tanh*, o método de otimização foi o Adam, a regularização L2 foi implantada com  $\alpha = 0.6$  e o número máximo de interações estipulado em 200 vezes.

O funcionamento da rede neural artificial simula o funcionamento do neurônio humano, também chamado de neurônio matemático. É composta por unidades de processamento, onde os “nós” representam os neurônios, conectados a outros neurônios por meio de conexões sinápticas, conforme representado na Figura 16 (Ferneda, 2006).

Figura 16 - Representação de uma rede neural artificial.



Fonte: Ferneda (2006).

## CONCLUSÃO

O presente estudo apresenta algumas limitações relacionadas ao preenchimento das fichas de notificação dos pacientes suspeitos de infecção pela COVID-19. Observou-se a influência da data de encerramento da ficha de notificação, uma vez que muitos pacientes ainda não haviam obtido um desfecho em relação à doença no momento de encerramento da ficha, ou ainda, as fichas não haviam sido encerradas. Dos mais de 170 mil registros, somente 180 foram selecionados para uso, devido a grande quantidade de registros inconsistentes, incorretos ou incompletos. Desta forma, torna-se necessário abordar a qualidade dos dados em saúde e a sua representatividade amostral, uma vez que a precisão dos modelos de aprendizagem de máquina depende da análise de dados consistentes.

A partir da análise de características demográficas e clínicas de pacientes, as variáveis que apresentaram maior influência para predição da internação de pacientes em UTI foram: internação hospitalar, raça e dor de garganta e a rede neural foi o modelo que atingiu a melhor performance para as métricas de *AUC* (0.917), sensibilidade (0.861) e especificidade (0.825). Apesar das limitações apresentadas acima relacionadas a qualidade da coleta dos dados, essa aplicação mostrou-se um método viável para a predição da admissão de pacientes infectados pela COVID-19 em UTI, uma vez que dos 180 casos apresentados a rede neural, 155 casos foram preditos corretamente em seu desfecho, enquanto 25 casos foram classificados de forma errada, entre falsos positivos e falsos negativos.

Com o surgimento de novas variantes e o aumento da imunização em todo o mundo, o comportamento do vírus se altera, conseqüentemente, os modelos precisam ser avaliados rotineiramente quanto a sua performance, uma vez que ao entrar novos dados pode aprender com ele e continuar a predizer com boa performance ou então não identificar essas novas alterações. Outro ponto a ser discutido é o potencial de generalização dos modelos de aprendizado de máquina, este modelo foi aplicado em uma população específica, com determinadas características de saúde. Sugere-se a replicação do estudo em outras populações.

Estes biomarcadores clínicos mostram-se relevantes para a prática clínica de Enfermagem aos pacientes com COVID-19 uma vez que são facilmente observáveis e podem ser rapidamente implementados para identificação dos pacientes com

probabilidade de declínio no quadro clínico. Assim, o modelo apresenta impacto positivo na prática assistencial à medida que fornece informação para a tomada de decisão de profissionais da saúde e gestores para uma necessidade de leitos em UTI e rápida mobilização de recursos materiais e humanos.

## REFERÊNCIAS

AL-HASHIMI, M.; HAMDAN, A. Artificial Intelligence and Coronavirus COVID-19: Applications, Impact and Future Implications. *In: ALAREENI, B., HAMDAN, A., ELGEDAWY, I. (ed.). The Importance of New Technologies and Entrepreneurship in Business Development: In the Context of Economic Diversity in Developing Countries. Lecture Notes in Networks and Systems*, v. 194, p. 830–843, 2021. DOI: [https://doi.org/10.1007/978-3-030-69221-6\\_64](https://doi.org/10.1007/978-3-030-69221-6_64)

ALIMADADI, A. *et al.* Artificial intelligence and machine learning to fight covid-19. **Physiological Genomics**, v. 52, n. 4, p. 200–202, 1 abr. 2020. DOI: <https://doi.org/10.1152/physiolgenomics.00029.2020>

AMER, A. Y. A. *et al.* Vital Signs Prediction for COVID-19 Patients in ICU. **Sensors**, v. 21, n. 23, 1 dez. 2021. DOI: <https://doi.org/10.3390/s21238131>

CHENG, F. Y. *et al.* Using Machine Learning to Predict ICU Transfer in Hospitalized COVID-19 Patients. **Journal of Clinical Medicine**, v. 9, n. 6, p. 1668, 1 jun. 2020. DOI: [10.3390/jcm9061668](https://doi.org/10.3390/jcm9061668)

CHENG, J. *et al.* Factors influencing nurses' behavioral intention toward caring for COVID-19 patients on mechanical ventilation: A cross-sectional study. **PLOS ONE**, v. 16, n. 11, p. e0259658, 1 nov. 2021. DOI: <https://doi.org/10.1371/journal.pone.0259658>

CORWIN, E. J.; FERRANTI, E. P. Integration of biomarkers to advance precision nursing interventions for family research across the life span. **Nursing outlook**, v. 64, n. 4, p. 292–298, 2016. DOI: [10.1016/j.outlook.2016.04.007](https://doi.org/10.1016/j.outlook.2016.04.007)

CUOCOLO, R. *et al.* Machine Learning in oncology: A clinical appraisal. **Cancer Letters**, v. 481, p. 55-62, 1 jul. 2020. Acesso em: 11 mar. 2021. DOI: [10.1016/j.canlet.2020.03.032](https://doi.org/10.1016/j.canlet.2020.03.032)

FERNEDA, E. Neural networks and its application in information retrieval systems. **Ciência da Informação**, v. 35, n. 1, p. 25–30, 2006. DOI: <https://doi.org/10.1590/S0100-19652006000100003>

FLORIANOPOLIS. Secretaria Municipal de Saúde. Covidômetro: o controle em nossas mãos. **Prefeitura de Florianópolis**, 2023. Disponível em: <https://covidometrofloripa.com.br/>. Acesso em: 23 mai. 2023.

FU, M. R. *et al.* Precision health: A nursing perspective. **International Journal of Nursing Sciences**, v. 7, n. 1, p. 5, 10 jan. 2020. DOI: 10.1016/j.ijnss.2019.12.008

HOU, W. *et al.* Machine learning predicts the need for escalated care and mortality in COVID-19 patients from clinical variables. **International Journal of Medical Sciences**, v. 18, n. 8, p. 1739–1745, 19 fev. 2021. DOI: 10.7150/ijms.51235

IZQUIERDO, J. L.; ANCOCHEA, J.; SORIANO, J. B. Clinical Characteristics and Prognostic Factors for Intensive Care Unit Admission of Patients With COVID-19: Retrospective Study Using Machine Learning and Natural Language Processing. **Journal of Medical Internet Research**, v. 22, n. 10, e21801, 1 out. 2020. DOI: 10.2196/21801

KWONG, J. C. *et al.* Posterior Urethral Valves Outcomes Prediction (PUVOP): a machine learning tool to predict clinically relevant outcomes in boys with posterior urethral valves. **Pediatric Nephrology**, v. 37, n. 5, p. 1067-1074, 2022. DOI: 10.1007/s00467-021-05321-3

LOPES JÚNIOR, L. C. Personalized Nursing Care in Precision-Medicine Era: **SAGE Open Nursing**, v. 7, 9 dez. 2021a. DOI: 10.1177/23779608211064713

LOPES JÚNIOR, L. C. The era of precision medicine and its impact on nursing: paradigm shifts? **Revista Brasileira de Enfermagem**, v. 74, n. 5, p. e740501, 28 jul. 2021b. DOI: <https://doi.org/10.1590/0034-7167.2021740501>

MAGUNIA, H. *et al.* Machine learning identifies ICU outcome predictors in a multicenter COVID-19 cohort. **Critical Care**, v. 25, n. 295, 1 dez. 2021. DOI: <https://doi.org/10.1186/s13054-021-03720-4>

MALTEZOU, H. C. *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. **Vaccine**, v. 41, n. 14, p. 2343-2348, 2023. DOI: 10.1016/j.vaccine.2023.01.067

MOGHADAS, S. M. *et al.* The impact of vaccination on COVID-19 outbreaks in the United States. **medRxiv**, 30 nov. 2020. DOI: <https://doi.org/10.1101/2020.11.27.20240051>

SUBUDHI, S. *et al.* Comparing machine learning algorithms for predicting ICU admission and mortality in COVID-19. **NPJ Digital Medicine**, v. 4, n. 1, p. 87, 1 dez. 2021. DOI: 10.1038/s41746-021-00456-x

YUAN, C. Precision Nursing: New Era of Cancer Care. **Cancer Nursing**, v. 38, n. 5, p. 333–334, 2015. DOI: 10.1097/NCC.0000000000000290

### 5.3 ARTIGO 3 – PREDIÇÃO DE ADMISSÕES NA UNIDADE DE TERAPIA INTENSIVA DE PACIENTES COM COVID-19 EM CINCO HOSPITAIS UNIVERSITÁRIOS DO BRASIL

De acordo com a Instrução Normativa 02/PEN/2021 pelo menos um dos manuscritos que compuseram os resultados da pesquisa, não deve ter sido submetido ou publicado antes da aprovação da tese pela banca examinadora. Por este motivo, o artigo 3, intitulado “Predição de admissões na Unidade de Terapia Intensiva de pacientes com COVID-19 em cinco hospitais universitários do Brasil” será submetido após a aprovação do trabalho.

#### **Predição de admissões na Unidade de Terapia Intensiva de pacientes com COVID-19 em cinco hospitais universitários do Brasil**

#### **Predicting Intensive Care Unit admissions of COVID-19 patients across five university hospitals in Brazil**

#### **Predicción del ingresos em la Unidad de Cuidados Intensivos de pacientes com COVID-19 en cinco hospitales universitarios de Brasil**

#### **RESUMO**

**Introdução:** Os pacientes contaminados pela COVID-19 podem apresentar uma evolução clínica variada, como casos assintomáticos da doença a acometimentos mais severos que necessitam de internação em Unidade de Terapia Intensiva. **Objetivo:** O objetivo deste estudo foi desenvolver um modelo de inteligência artificial para prever a admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, a partir do referencial teórico da Enfermagem de Precisão. **Método:** Estudo retrospectivo, multicêntrico, que incluiu 547 pacientes com diagnóstico clínico positivo para COVID-19, que passaram por internação em um dos cinco hospitais universitários do Brasil. A partir da combinação de variáveis relacionadas à Enfermagem de Precisão, foram testados oito modelos de inteligência artificial, incluindo rede neural, *AdaBoost*, regressão logística, floresta aleatória, *K Nearest Neighbor*, *Naive Bayes*, *Support Vector Machine* e árvore de decisão que poderiam prever a probabilidade de internação em Unidade de Terapia Intensiva. O desempenho dos modelos foi avaliado por meio de técnicas de validação cruzada dos dados, observando as métricas de área acima da curva, sensibilidade, especificidade e matriz de confusão. **Resultados:** A área acima da curva dos oito algoritmos de inteligência artificial variou de 0.585 a 0.668, sendo que a árvore de decisão foi o

algoritmo que atingiu a melhor performance. No modelo de árvore de decisão, as variáveis preditoras de maior importância foram: idade, internação no hospital universitário vinculado a Universidade Federal do Amazonas e o número de pessoas residente em domicílio. **Conclusão:** O algoritmo de árvore de decisão apresentou a melhor performance preditiva, tendo como métricas: AUC = 0.668, sensibilidade = 0.633 e especificidade = 0.669. O uso do modelo como ferramenta de apoio à tomada de decisão de enfermeiros auxilia na identificação de rebaixamento do quadro, indicando precocemente os pacientes com maior probabilidade de internação em Unidade de Terapia Intensiva e reduzindo o risco de mortalidade e uso de ventilação mecânica. No entanto, é necessário um refinamento das variáveis preditoras e avaliações frequentes quanto a sua capacidade preditiva, acredita-se que a inclusão da variável vacinação poderia melhorar a performance preditiva do modelo.

**Palavras-chave:** Medicina de Precisão; COVID-19; Inteligência artificial; Previsões; Algoritmos.

## ABSTRACT

**Introduction:** Patients infected by COVID-19 may present a varied clinical evolution, from asymptomatic cases of the disease to more severe cases that require admission to the Intensive Care Unit. **Objective:** The aim of this study was to develop an artificial intelligence model to predict the admission of patients infected with COVID-19 in Intensive Care Units, based on the theoretical framework of Precision Nursing. **Method:** A retrospective, multicenter study, which included 547 patients with a positive clinical diagnosis for COVID-19, who had been admitted to one of five university hospitals in Brazil. From the combination of variables related to Precision Nursing, eight artificial intelligence models were tested, including neural network, AdaBoost, logistic regression, random forest, K Nearest Neighbor, Naive Bayes, Support Vector Machine and decision tree that could predict the probability of admission to Intensive Care Unit. The performance of the models was evaluated using cross-validation techniques of the data, observing the metrics of area under the curve, sensitivity, specificity and confusion matrix. **Results:** The results showed that the predictor variables of admission to Intensive Care Unit were age, admission to the university hospital linked to the Federal University of Amazonas and the number of people residing at home. The area under the curve of the eight artificial intelligence algorithms ranged from 0.585 to 0.668, while the decision tree model showed an area under the curve of 0.668. **Conclusion:** The decision tree algorithm showed the best predictive performance, with the following metrics: AUC = 0.668, sensitivity = 0.633 and specificity = 0.669. The use of the model as a tool to support nurses' decision making helps to identify downgrading of the condition, indicating early the patients most likely to be admitted to the Intensive Care Unit and reducing the risk of mortality and use of mechanical ventilation. However, a refinement of the predictor variables and frequent evaluations of their predictive capacity are necessary, and it is believed that the inclusion of the vaccination variable could improve the predictive performance of the model.

**Keywords:** Precision Medicine; COVID-19; Artificial Intelligence; Forecasting; Algorithms.

## RESUMEN

**Introducción:** Los pacientes contaminados por COVID-19 pueden presentar una evolución clínica variada, desde casos asintomáticos de la enfermedad hasta acometidas más graves que requieren de internamiento en la Unidad de Terapia Intensiva. **Objetivo:** El objetivo de este estudio fue desarrollar un modelo de inteligencia artificial para predecir el ingreso de pacientes infectados con COVID-19 en las Unidades de Cuidados Intensivos, basado en el marco teórico de la Enfermería de Precisión. **Método:** Estudio retrospectivo, multicéntrico, que incluyó a 547 pacientes con diagnóstico clínico positivo para COVID-19, que pasaron por la internación en uno de los cinco hospitales universitarios de Brasil. A partir de la combinación de variables relacionadas con la Enfermería de Precisión, se probaron ocho modelos de inteligencia artificial, entre los que se encontraban la red neuronal, AdaBoost, la regresión logística, el bosque aleatorio, K Nearest Neighbor, Naive Bayes, Support Vector Machine y el árbol de decisión que podían predecir la probabilidad de ingreso en la Unidad de Cuidados Intensivos. El rendimiento de los modelos se evaluó mediante técnicas de validación cruzada de los datos, observando las métricas de área bajo la curva, sensibilidad, especificidad y matriz de confusión. **Resultados:** Los resultados mostraron que las variables predictoras de ingreso en la Unidad de Cuidados Intensivos fueron la edad, el ingreso en el hospital universitario vinculado a la Universidad Federal de Amazonas y el número de personas que residen en el domicilio. El área bajo la curva de los ocho algoritmos de inteligencia artificial osciló entre 0,585 y 0,668, mientras que el modelo de árbol de decisión mostró un área bajo la curva de 0,668. **Conclusión:** El algoritmo de árbol de decisión mostró el mejor rendimiento predictivo, con las siguientes métricas: AUC = 0,668, sensibilidad = 0,633 y especificidad = 0,669. El uso del modelo como herramienta de apoyo a la toma de decisiones del personal de enfermería ayuda a identificar la degradación del cuadro, indicando precozmente los pacientes con mayor probabilidad de ingreso en la Unidad de Cuidados Intensivos y reduciendo el riesgo de mortalidad y de uso de ventilación mecánica. Sin embargo, es necesario un refinamiento de las variables predictoras y evaluaciones frecuentes de su capacidad predictiva, y se cree que la inclusión de la variable vacunación podría mejorar el rendimiento predictivo del modelo.

**Palabras clave:** Medicina de Precisión; COVID-19; Inteligencia Artificial; Predicción; Algoritmos.

## INTRODUÇÃO

Os pacientes com quadros leves característicos da COVID-19 apresentam os seguintes sinais e sintomas: febre, tosse, fadiga e mialgia. Entretanto, após uma semana do início dos sintomas podem evoluir para casos graves da doença com acometimentos mais severos como dispneia grave e hipoxemia (Covino *et al.*, 2020).

As estatísticas apontam que 20 a 30% dos pacientes que apresentam as formas moderada e grave da doença necessitam de internação em leito hospitalar. E

dos pacientes hospitalizados, a literatura difere um pouco, estudos apontam que a taxa de internação em Unidade de Terapia Intensiva (UTI) se concentra entre 5 e 12%, podendo chegar até 25% de pacientes que necessitam de tratamento intensivo (Cheng *et al.*, 2020; Covino *et al.*, 2020; Hou *et al.*, 2021).

Tradicionalmente os leitos de UTI apresentam altas taxas de ocupação, não apenas por emergências relacionadas a COVID-19, mas uma série de condições clínicas que necessitam de cuidados intensivos. Com a deflagração da pandemia, somaram-se essas duas demandas por leitos UTI, variando a necessidade de acordo com o país e com o comportamento do vírus. Os países de baixa e média renda, apresentam uma disponibilidade de 0,1 a 2,5 leitos de UTI por 100.000 habitantes, enquanto países de alta renda, como Mônaco, a disponibilidade de leitos de UTI está em 59.5 para cada 100.000 habitantes (Ma; Vervoort, 2020).

A Organização Mundial de Saúde (OMS) recomenda a necessidade de 1 a 3 leitos de UTI para cada 10.000 habitantes. No Brasil, os leitos estão distribuídos entre o Sistema Único de Saúde e o setor privado, entretanto, a maioria da população utiliza os serviços públicos de saúde. Considerando os leitos de UTI no SUS, apenas 11 estados brasileiros apresentaram mais de 1 leito de UTI para cada 10.000 habitantes, enquanto no setor privado todos os estados apresentaram mais de 3 leitos de UTI para cada 10.000 habitantes, com exceção do estado de Santa Catarina que apresentou 2,61 leitos. Ademais, os estados apresentam uma distribuição desigual de leitos de UTI por área geográfica, além disso, os leitos estão concentrados nas capitais, como é o caso de Manaus, no estado do Amazonas (Palamim; Marson, 2020). Os serviços de saúde são distribuídos de forma desigual no Brasil e a disponibilidade de leitos de UTI também varia entre as cidades, atingindo os menores índices entre as comunidades mais pobres e negras (Pereira *et al.*, 2020).

Diante desse cenário, as tecnologias em saúde mostraram-se como importantes aliadas na busca por soluções para o enfrentamento da COVID-19. Estudos anteriores utilizaram-se de técnicas de inteligência artificial para prever a transferência de pacientes para UTI (Cheng *et al.*, 2020; Covino *et al.*, 2020; Hou *et al.*, 2021). Essas estratégias apresentam potencial para serem utilizadas em um contexto de gestão de leitos de UTI, especialmente os algoritmos de aprendizado de máquina apresentaram bons resultados no rastreamento da propagação viral,

monitoramento de pacientes, métodos de diagnóstico, terapia e descoberta de drogas (Heidari *et al.*, 2022).

A COVID-19 manifesta-se de diferentes formas nos pacientes, enquanto alguns indivíduos apresentam sintomas leves da doença, outros desenvolvem a forma moderada a grave da infecção, podendo levar ao óbito (Cheng *et al.*, 2020; Covino *et al.*, 2020; Hou *et al.*, 2021). O que aponta que pacientes com uma mesma condição clínica podem apresentar cursos variados da doença, tornando diferentes respostas do indivíduo em determinadas condições. O mesmo acontece para o tratamento, a mesma medicação pode agir de maneiras diferentes em indivíduos com a mesma situação. A explicação fundamenta-se nas características genéticas de um grupo de indivíduos, o que remete a necessidade de individualização dos cuidados em saúde (Lopes Júnior, 2021a).

Nessa busca por individualização dos cuidados em saúde o termo “precisão” passou a ser usado como sinônimo de personalização dos cuidados em saúde voltando-se para intervenções mais assertivas de cuidado. Quando esses conceitos são aplicados na área da enfermagem, fundamentam os estudos de Enfermagem de Precisão, definido como a aplicação dos cuidados de enfermagem voltados para as necessidades específicas de um único indivíduo, a partir da integração de grandes bancos de dados e integração de informações relacionadas aos hábitos de vida, contexto em que vive e a sua influência social, econômica e cultura sobre a saúde. Essas associações fornecem informações que irão direcionar o cuidado individual aos pacientes, com vistas ao alcance do bem-estar em saúde (Yuan, 2015; Fu *et al.*, 2020; Lopes Júnior, 2021b).

Para tanto, o estudo objetivou desenvolver um modelo de inteligência artificial para prever a admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, a partir do referencial teórico da Enfermagem de Precisão, em cinco hospitais universitários brasileiros que foram referência para o atendimento.

## **MÉTODO**

Esse estudo faz parte do macroprojeto de pesquisa “Avaliação do cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros”, o qual objetiva avaliar o cuidado de enfermagem a pacientes com COVID-19 em

hospitais universitários brasileiro em cinco dimensões: gestão hospitalar; liderança e gestão do cuidado; ambiente de prática profissional; experiência do paciente e continuidade do cuidado.

## TIPO DE ESTUDO

Estudo retrospectivo, multicêntrico, realizado em cinco hospitais universitários brasileiros, nas seguintes regiões do país: 1) Sul: Hospital Universitário Polydoro Ernani de São Thiago (Universidade Federal de Santa Catarina); 2) Sudeste: Hospital Universitário (Universidade Federal de São Paulo); Hospital Universitário Clementino Fraga Filho (Universidade Federal do Rio de Janeiro); 3) Nordeste: Hospital Universitário Onofre Lopes (Universidade Federal do Rio Grande do Norte); 4) Norte: Hospital Universitário Getúlio Vargas (Universidade Federal do Amazonas).

## COLETA DE DADOS

A coleta de dados foi integrada às dimensões experiência do paciente e continuidade do cuidado, do macroprojeto de pesquisa. Os dados foram coletados de abril a dezembro de 2021 via entrevista telefônica, a partir de lista disponibilizada pelos Hospitais Universitários com a relação dos pacientes que passaram por internação hospitalar. Durante as entrevistas foram aplicados inicialmente os instrumentos *Care Transitions Measure* (CTM-15), o qual objetiva avaliar a transição do cuidado de serviços hospitalares para o domicílio e o Instrumento *Patient Measure Of Safety* (PMOS), que analisa a segurança do paciente no contexto hospitalar. Vale ressaltar que estes instrumentos não fazem parte do foco de análise do presente estudo, mas sim, os dados sociodemográficos utilizados para a caracterização dos pacientes, informados logo após a aplicação dos instrumentos mencionados acima (Acosta *et al.*, 2017; Mello, Barbosa, 2021).

A coordenação geral do projeto confeccionou um manual instrutivo para guiar os coletadores durante a coleta de dados. Também realizou uma capacitação online demonstrando o fluxograma que deveria ser seguido durante a coleta de dados. Visando a padronização da coleta de dados, as tentativas de contato, incluindo data,

horário e o motivo das perdas, quando foi o caso, foram registradas em uma planilha do Excel (Melo *et al.*, 2021; Costa *et al.*, 2021).

A partir da lista de pacientes que passaram por internação, recebida dos hospitais, os coletadores faziam um primeiro contato com os pacientes. Quando o paciente não atendeu ao telefonema, foi tentando contato por mais duas vezes, totalizando três vezes, em turnos e horários diferentes. Se ainda assim, não fosse possível o contato, o paciente entrava para a planilha de perdas. Foram considerados motivos de perda: telefone não correspondia ao contato dos pacientes, contato não efetivado após esgotado o período da coleta, paciente negou-se a participar e outros motivos.

Foi utilizada uma entrevista estruturada com opções de resposta pré-especificadas no instrumento de coleta de dados, apresentado no Apêndice B. As respostas foram registradas na plataforma *Googleforms*®, para cada paciente foi gerado um número de identificação e uma dupla checagem com dados adicionais como nome, data de nascimento, data de internação e de alta. Além disso, após o consentimento de participação na pesquisa foi iniciada a gravação do áudio via gravador portátil ou aplicativo de gravação em smartphone e/ou notebook/computador. Ao final da entrevista foi questionado ao participante o seu interesse em receber os resultados da pesquisa via e-mail.

## VARIÁVEIS DO ESTUDO

A seguir, serão descritas as variáveis de entrada do modelo relacionadas a Enfermagem de Precisão.

Quadro 6 – Tipo das variáveis do estudo

<b>Variáveis sociodemográficas</b>	<b>Tipo</b>
Idade	Variável contínua
Gênero	Variável categórica: masculino, feminino, outros e prefiro não informar
Grau de instrução	Variável categórica: sem instrução e menos de 1 ano de estudo, ensino fundamental incompleto, ensino fundamental completo, ensino médio incompleto, ensino médio completo, ensino superior incompleto, ensino superior completo.
Raça	Variável categórica: branca, preta, parda, indígena, amarela, não sei responder.
<b>Biomarcadores clínicos</b>	
Dias de internação	Variável contínua
Dias de internação em UTI	Variável contínua

Uso de ventilação mecânica	Variável categórica: sim, não.
Doença respiratório crônica	Variável categórica: sim, não.
Hipertensão arterial sistêmica	Variável categórica: sim, não.
Doenças cardiovasculares	Variável categórica: sim, não.
Diabetes Mellitus	Variável categórica: sim, não.
Doenças renais	Variável categórica: sim, não.
Obesidade	Variável categórica: sim, não.
Câncer	Variável categórica: sim, não.
Febre	Variável categórica: sim, não.
Fadiga	Variável categórica: sim, não.
Falta de ar	Variável categórica: sim, não.
Tosse	Variável categórica: sim, não.
Perda de olfato e paladar	Variável categórica: sim, não.
Dor de cabeça	Variável categórica: sim, não.
Dor no corpo	Variável categórica: sim, não.
Náuseas e vômito	Variável categórica: sim, não.
Diarreia	Variável categórica: sim, não.
<b>Hábitos de vida</b>	
Histórico de tabagismo	Variável categórica: sim, não.
<b>Determinantes sociais e contexto ao qual o paciente está inserido</b>	
Município de residência	Variável nominal
Renda familiar	Variável categórica: até R\$2.090, R\$2.091 a R\$5.225, R\$5.225 a R\$10.450, Mais de R\$10.450, Sem rendimentos, Prefiro não responder.
Número de pessoas residentes no domicílio	Variável contínua

Fonte: Elaborado pela autora (2023).

## POPULAÇÃO E AMOSTRA

Para o cálculo amostral foi utilizado o programa *Winpepi*, versão 11.65. A amostra foi calculada a partir do número total de leitos das instituições hospitalares, com base na margem de erro absoluta, para estimar uma média do número de pacientes que deveriam ser incluídos no estudo. A margem de erro considerada para o PMOS foi de 0,3 pontos e desvio padrão de 1,28 (Taylor *et al.*, 2020). Para o CTM-15 a margem de erro foi de até 04 pontos e o desvio padrão de 17,1 (Weber; Lima; Acosta, 2019). O nível de confiança foi de 95%.

A amostra mínima deveria ser composta por 365 participantes e para as situações de comparação entre os hospitais, foi estimada uma amostra mínima de 429 pacientes, variando entre 28 e 136 pacientes por hospital, conforme apresentado na tabela 4. O macroprojeto de pesquisa realizou a coleta de dados em 10 hospitais universitários brasileiros, sendo dois em cada região do país. No entanto, destes, apenas cinco hospitais atingiram o número mínimo de amostras consideradas no cálculo amostral e, por este motivo, foram incluídos na presente pesquisa.

Tabela 4 - Apresentação do cálculo amostral e do cálculo amostral para comparação por Hospital Universitário.

Hospital Universitário	Cálculo amostral	Cálculo amostral comparação
Hospital Universitário Polydoro Ernani de São Thiago – Universidade Federal de Santa Catarina	63	73
Hospital Universitário – Universidade Federal de São Paulo	136	136
Hospital Universitário Clementino Fraga Filho – Universidade Federal do Rio de Janeiro	74	74
Hospital Universitário Onofre Lopes – Universidade Federal do Rio Grande do Norte	64	73
Hospital Universitário Getúlio Vargas –Universidade Federal do Amazonas	28	73
<b>Total</b>	<b>365</b>	<b>429</b>

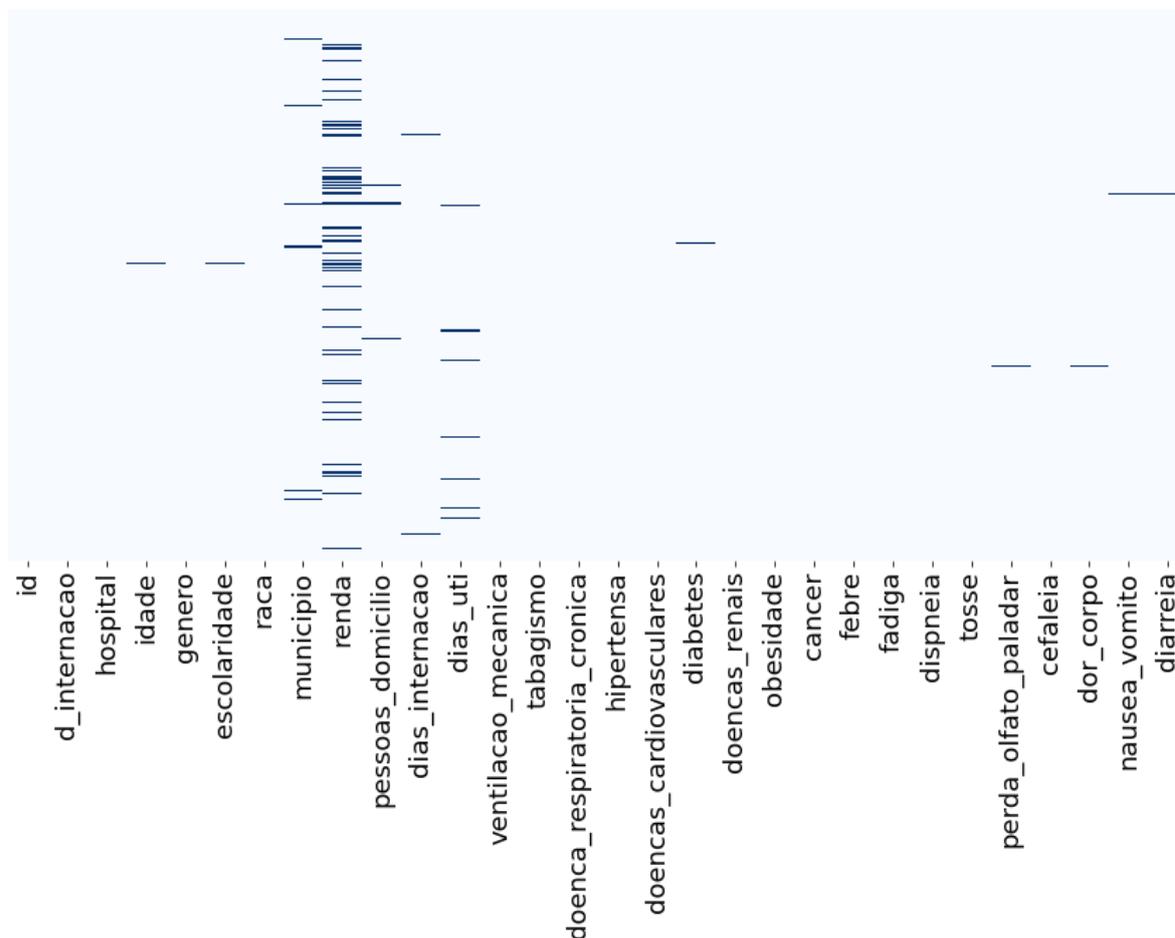
Fonte: Elaborado pela autora (2023).

## CONSTRUÇÃO DO MODELO DE APRENDIZADO DE MÁQUINA

Para o desenvolvimento do modelo preditivo foram percorridas as seguintes etapas: pré-processamento de dados, engenharia de atributos, exploração descritiva dos dados, construção do modelo e avaliação do modelo.

Na fase de pré-processamento dos dados, inicialmente foram identificados os valores ausentes no banco de dados, conforme apresentado na Figura 17. Em uma escala de cores que varia de branco a azul escuro, as colunas que apresentam dados faltantes estão destacadas em azul escuro. Observa-se a variável renda com o maior número de dados faltantes.

Figura 17 - Apresentação dos valores ausentes no banco de dados em uma escala de cores.



Fonte: Cientista de dados e programador da pesquisa (2023).

Foram utilizadas algumas estratégias para padronização dos dados, são elas: a categoria '99 – entrevista suspensa' foi declarada como valor faltante; as categorias 'sim' e 'não' foram declaradas como 1 e 0, respectivamente; a categoria 'não sabe/não lembra' na variável idade foi tratada como valor faltante; a categoria '6- não sei responder' na variável raça foi declarada como valor faltante. Na variável número de pessoas em domicílio, o registro 'está em clínica de repouso' foi declarado como um registro de 20 pessoas e 'prefiro não responder' foi tratado como valor faltante. Na variável dias de internação em UTI a categoria 'não sabe/não lembra' foi transformada em valor faltante; na mesma variável, dias maior que 0 foram transformados em 1, de outra forma valor corresponde a 0.

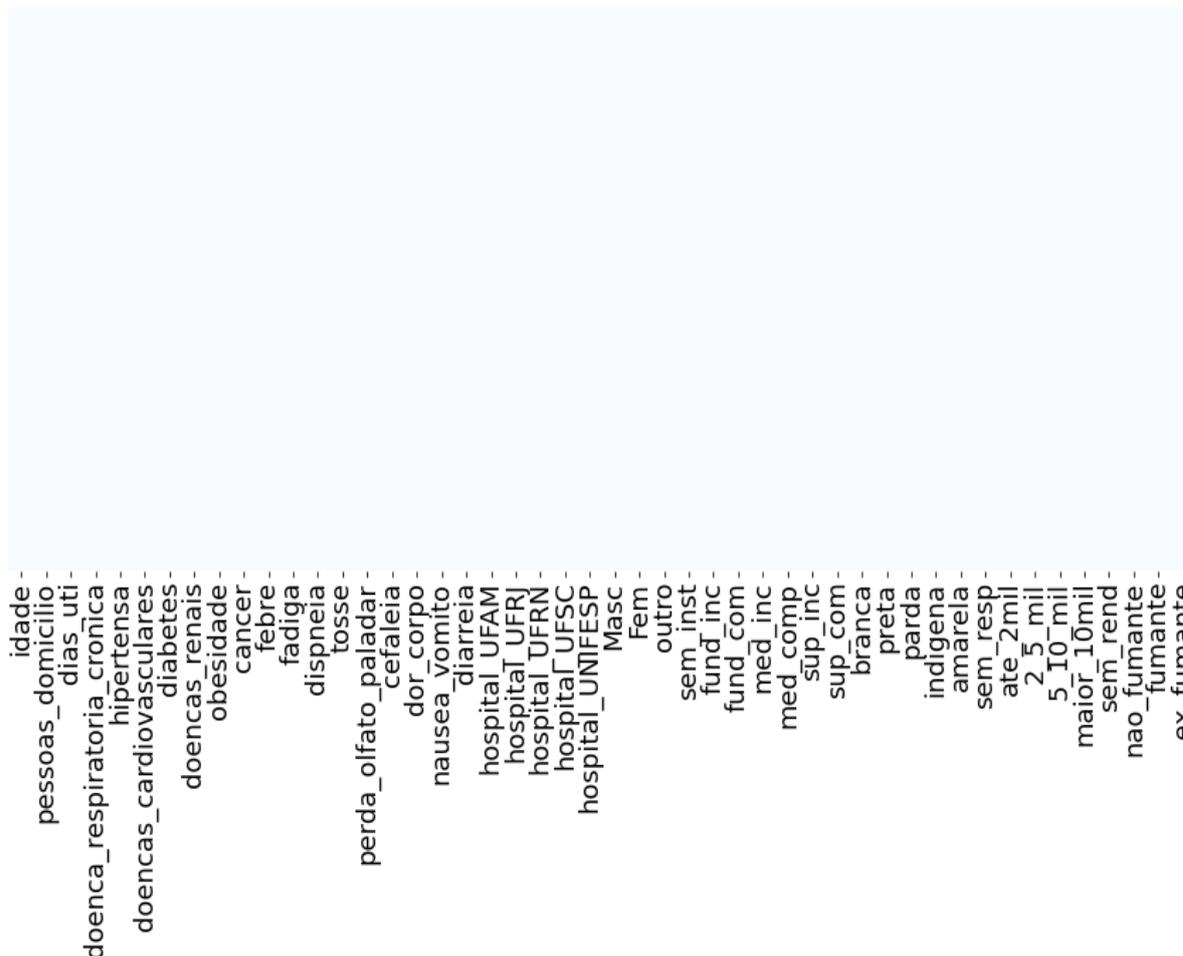
As variáveis: município de residência, data da internação e dias de internação foram retiradas do banco de dados, pois não apresentavam informações relevantes

para a etapa de modelagem. A variável: ventilação mecânica também foi retirada dos dados, pois poderia sugerir o desfecho de internação em UTI. Os 13 pacientes que não possuíam registro para o desfecho de dias de internação em UTI foram retirados do banco de dados.

Foram imputados os valores mais frequentes (moda) aos demais valores faltantes. Na variável renda, foram imputados 71 valores, na variável número de pessoas em domicílio 4 valores, para escolaridade e tabagismo foram imputados 2 valores. As variáveis: idade, doença respiratória crônica, doenças cardiovasculares, diabetes, doenças renais, perda de olfato e paladar, dor no corpo, náusea e vômito e diarreia foram imputados 1 único valor.

As variáveis idade e número de pessoas em domicílio foram mantidas como variáveis numéricas e as demais variáveis foram consideradas categóricas. As variáveis categóricas foram transformadas em valores binários 0 ou 1, por meio da técnica *one-hot encoding* para que os dados pudessem ser modelados como valores numéricos. Após aplicação da técnica, o banco de dados passou de 25 para 48 variáveis e houve uma renomeação das variáveis para facilitar o entendimento. Por exemplo, a variável 'escolaridade\_3 – ensino fundamental completo' passou a ser 'fund\_comp'. Após realizadas as técnicas para padronização da informação, imputados os valores ausentes e renomeado as variáveis, a Figura 18 apresenta cada uma das variáveis sem apresentar valores ausentes. No Apêndice D deste estudo, pode ser consultado o tratamento completo dos dados até a construção do modelo de inteligência artificial.

Figura 18 - Apresentação das variáveis após o tratamento de dados sem conter valores ausentes.



Fonte: Cientista de dados e programador da pesquisa (2023).

## ANÁLISE DE DADOS E VALIDAÇÃO DO MODELO

Para as variáveis contínuas: idade e número de pessoas em domicílio foram calculadas média, mediana e intervalo interquartil. As variáveis categóricas foram relatadas como número absoluto e frequência relativa (porcentagem), em relação ao desfecho primário de internação em UTI.

O desenvolvimento do trabalho foi realizado com implementações em linguagem de programação e exploração visual dos dados no *Python*. Também se utilizou os *softwares Orange Data Mining* e *Knime Analytics Platform* para identificação dos melhores modelos, os quais são chamados de *softwares low code* por conter pouca linguagem de programação. Os modelos treinados foram extraídos da plataforma *Knime Analytics* e importados e disponibilizados em uma página *Web*

através da ferramenta *Streamlit*, a qual será apresentada em detalhes no manuscrito 4. O Quadro 7 apresenta o objetivo de cada etapa da pesquisa e o *software* utilizado em cada uma delas.

Quadro 7 - Softwares utilizados em cada etapa da pesquisa.

	<b>Coleta dos dados</b>	<b>Manipulação dos dados</b>	<b>Modelagem</b>	<b>Publicação dos modelos</b>
<b>Objetivo</b>	Pesquisa COVID-19	Limpeza, organização e padronização dos dados	Definição dos melhores modelos	Disponibilizar os resultados (front-end)
<b>Software</b>	<i>Google Forms</i> <i>Excel</i>	<i>Excel</i> <i>Python</i>	<i>Orange Data Mining</i> <i>Knime Analytics Platform</i>	<i>Python</i> <i>Streamlit</i>

Fonte: Elaborado pela autora (2023).

Foram testados os seguintes modelos: rede neural, *AdaBoost*, regressão logística, floresta aleatória, *K Nearest Neighbor*, *Naive Bayes*, *Support Vector Machine* e árvore de decisão. A parametrização dos modelos decorreu de um processo iterativo, selecionando os algoritmos de melhor desempenho, a partir de técnicas de validação cruzada dos dados, observando as métricas de área acima da curva, sensibilidade, especificidade e matriz de confusão.

## ASPECTOS ÉTICOS

Este estudo foi aprovado pelo Comitê de Ética em Pesquisa da Universidade Federal de Santa Catarina (proponente do estudo), CAAE 38912820.3.1001.0121 e parecer de aprovação número 4.347.463 e recebeu autorização institucional dos demais hospitais universitários brasileiros envolvidos na pesquisa. Além disso, foi endossado pela 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 (Collins *et al.*, 2015).

## RESULTADOS

Durante o período do estudo, um total de 968 pacientes responderam à pesquisa, sendo 643 respondentes do questionário CTM-15 e 541 respondentes do questionário PMOS. A tabela 5 apresenta o número de pacientes por hospital e questionário. O mesmo paciente poderia responder os dois instrumentos, portanto, na etapa seguinte foram excluídos os participantes que haviam respondido os dois formulários.

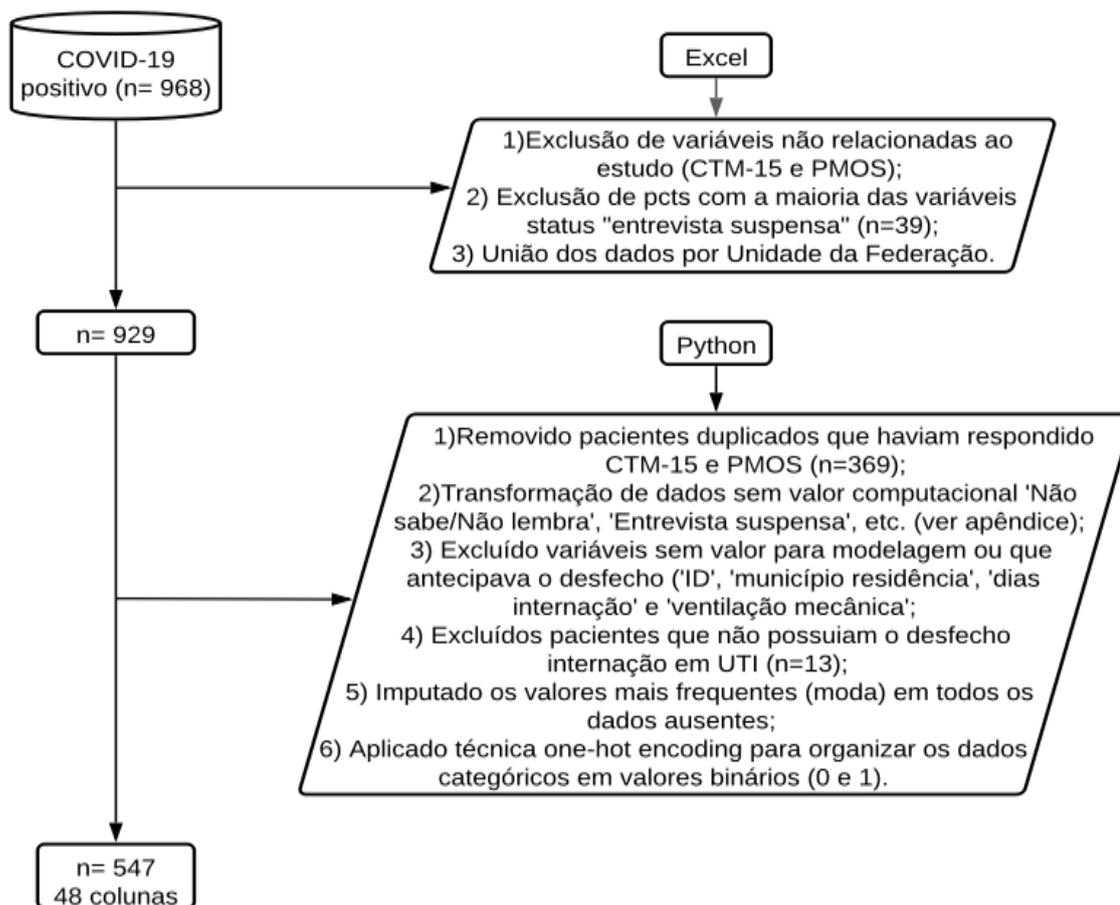
Tabela 5 - Número de participantes da pesquisa por hospital e por questionário.

Hospital Universitário	Coletado		Total
	CTM	PMOS	
Hospital Universitário Polydoro Ernani de São Thiago – Universidade Federal de Santa Catarina	78	74	152
Hospital Universitário – Universidade Federal de São Paulo	147	136	283
Hospital Universitário Clementino Fraga Filho – Universidade Federal do Rio de Janeiro	107	83	190
Hospital Universitário Onofre Lopes – Universidade Federal do Rio Grande do Norte	79	73	152
Hospital Universitário Getúlio Vargas –Universidade Federal do Amazonas	116	75	191
<b>Total</b>	<b>643</b>	<b>541</b>	<b>968</b>

Fonte: Elaborado pela autora (2023).

Os dados referentes aos pacientes positivos para COVID-19 e que preenchem os demais critérios de inclusão do estudo resultaram em 968 pacientes. Em um primeiro momento no Microsoft Excel foram excluídos os pacientes que apresentavam mais de três variáveis como ‘entrevista suspensa’, resultando em 929 registros. Em seguida, após o tratamento de dados no *Python* resultaram em 547 pacientes, correspondendo a amostra do estudo, conforme evidenciado no fluxograma apresentado na Figura 19.

Figura 19- Fluxograma de tratamento dos dados



Fonte: Elaborado pela autora (2023).

Os dados foram agrupados em relação à internação em UTI para a exploração descritiva, conforme a Tabela 6. Ao realizar o agrupamento das variáveis categóricas foram considerados somente os dados com resposta "sim" ou 1 para internação em UTI. As variáveis numéricas, referentes à idade e ao número de pessoas em domicílio também foram agrupadas pela variável alvo, apontando a média, mediana, quartil 1 (correspondente a 25% dos dados) e quartil 3 (referente a 75% dos dados).

Tabela 6 - Exploração descritiva dos dados em relação à internação em UTI.

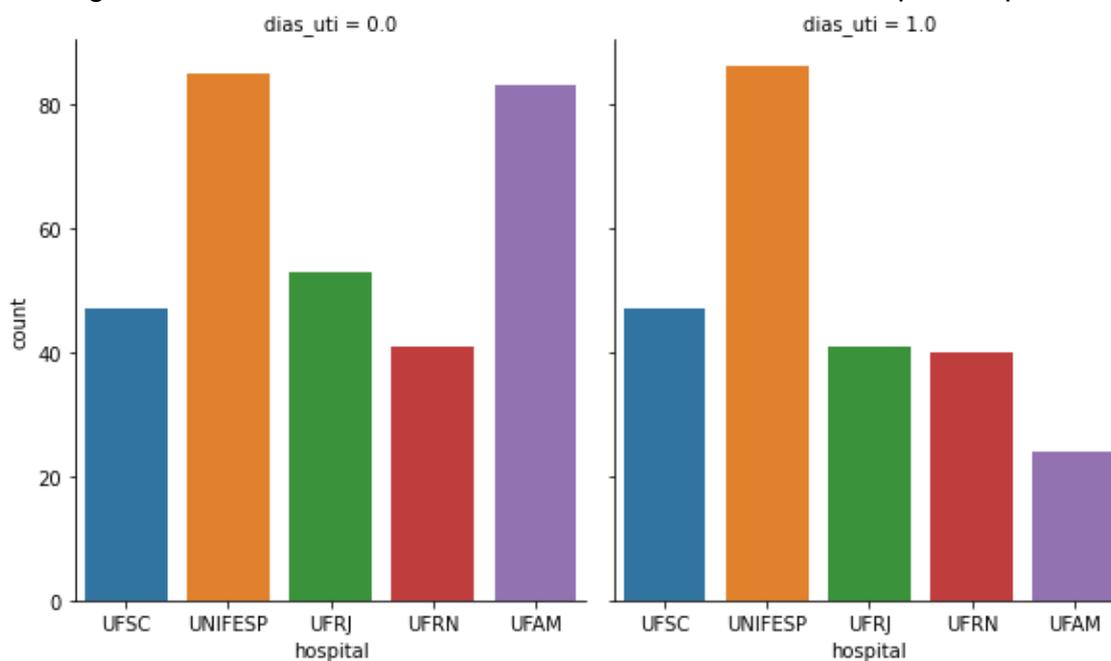
	Não internados em UTI	%	Internação em UTI	%	Total variável	Total de pacientes
Idade						
Média	56,06		55,06			
Mediana (mín.-máx.)	55		56			
Q1 (25%)	43		45			
Q3 (75%)	67		67			
Pessoas em domicílio						
Média	3,27		3,13			
Mediana (mín.-máx.)	3		3			
Q1 (25%)	2		2			
Q3 (75%)	4		4			
Dispneia	230	54%	196	46%	426	77,88%
Fadiga	221	52%	200	48%	421	76,97%
Tosse	211	56%	168	44%	379	69,29%
Dor no corpo	211	56%	165	44%	376	68,74%
Febre	204	55%	169	45%	373	68,19%
Não fumante	194	57%	147	43%	341	62,34%
Cefaleia	170	57%	126	43%	296	54,11%
Perda olfato/paladar	170	59%	119	41%	289	52,83%
Hipertensão	168	59%	118	41%	286	52,29%
Sexo masculino	146	52%	133	48%	279	51,01%
Renda até R\$ 2 mil	153	57%	115	43%	268	48,99%
Sexo feminino	162	61%	102	39%	264	48,26%
Cor parda	133	58%	98	42%	231	42,23%
Cor branca	125	54%	105	46%	230	42,05%
Diarreia	132	59%	91	41%	223	40,77%
Ex fumante	105	55%	85	45%	190	34,73%
Náusea e vômito	117	62%	73	38%	190	34,73%
Renda de R\$ 2 a 5 mil	111	59%	78	41%	189	34,55%
Ensino médio completo	104	58%	75	42%	179	32,72%
Diabetes	108	61%	70	39%	178	32,54%
Hospital UNIFESP	85	50%	86	50%	171	31,26%
Obesidade	81	54%	70	46%	151	27,61%
Doenças cardiovasculares	85	62%	52	38%	137	25,05%
Ensino fundamental incompleto	77	58%	55	42%	132	24,13%
Hospital UFAM	83	78%	24	22%	107	19,56%
Doença respiratória crônica	55	52%	51	48%	106	19,38%
Doenças renais	65	66%	34	34%	99	18,1%
Hospital UFSC	47	50%	47	50%	94	17,18%
Hospital UFRJ	53	56%	41	44%	94	17,18%
Hospital UFRN	41	51%	40	49%	81	14,81%
Ensino superior completo	37	51%	35	49%	72	13,16%
Cor preta	43	60%	29	40%	72	13,16%
Ensino fundamental completo	25	46%	29	54%	54	9,87%
Câncer	32	63%	19	37%	51	9,32
Renda de R\$ 5 a 10 mil	24	48%	26	52%	50	9,14%
Ensino superior incompleto	27	61%	17	39%	44	8,04%
Ensino médio incompleto	27	66%	14	34%	41	7,5%
Sem instrução	12	48%	13	52%	25	4,57%
Sem renda	11	46%	13	54%	24	4,39%
Renda maior que R\$ 10 mil	10	62%	6	38%	16	2,93%
Fumante	10	62%	6	38%	16	2,93%

Amarela	5	83%	1	17%	6	1,1%
Sexo – Outro	1	25%	3	75%	4	0,73%
Raça Indígena	1	25%	3	75%	4	0,73%
Raça – Sem resposta	2	50%	2	50%	4	0,73%

Fonte: Elaborado pela autora (2023).

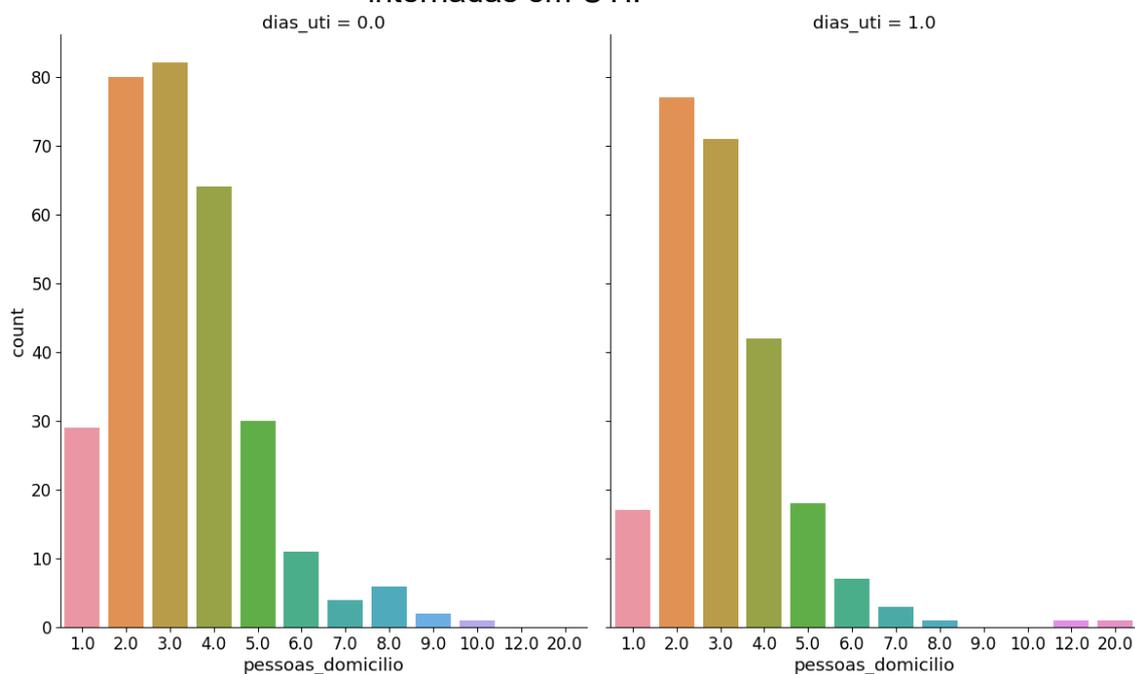
Algumas variáveis também foram exploradas de forma visual em relação ao desfecho de interesse, como o hospital de referência (Figura 20), número de pessoas em domicílio (Figura 21), tabagismo (Figura 22) e doença respiratória crônica (Figura 23).

Figura 20 - Pacientes não internados e internados em UTI por hospital.



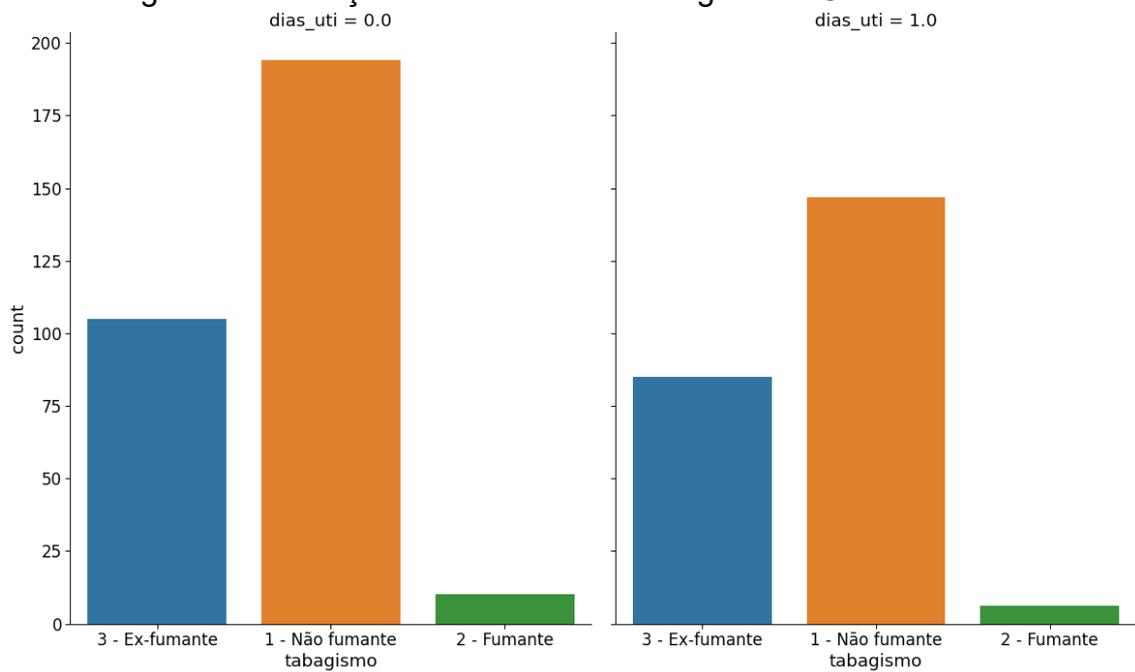
Fonte: Elaborado pela autora (2023).

Figura 21 – Número de pessoas residentes no mesmo domicílio não internadas e internadas em UTI.



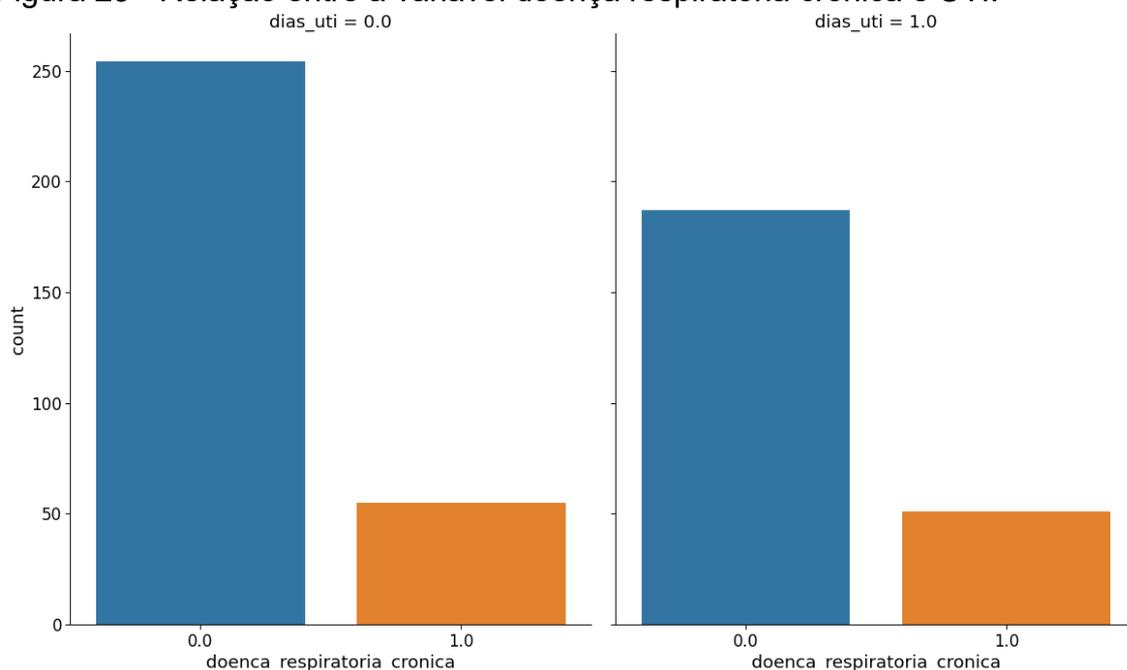
Fonte: Elaborado pela autora (2023).

Figura 22 - Relação entre a variável tabagismo e UTI.



Fonte: Elaborado pela autora (2023).

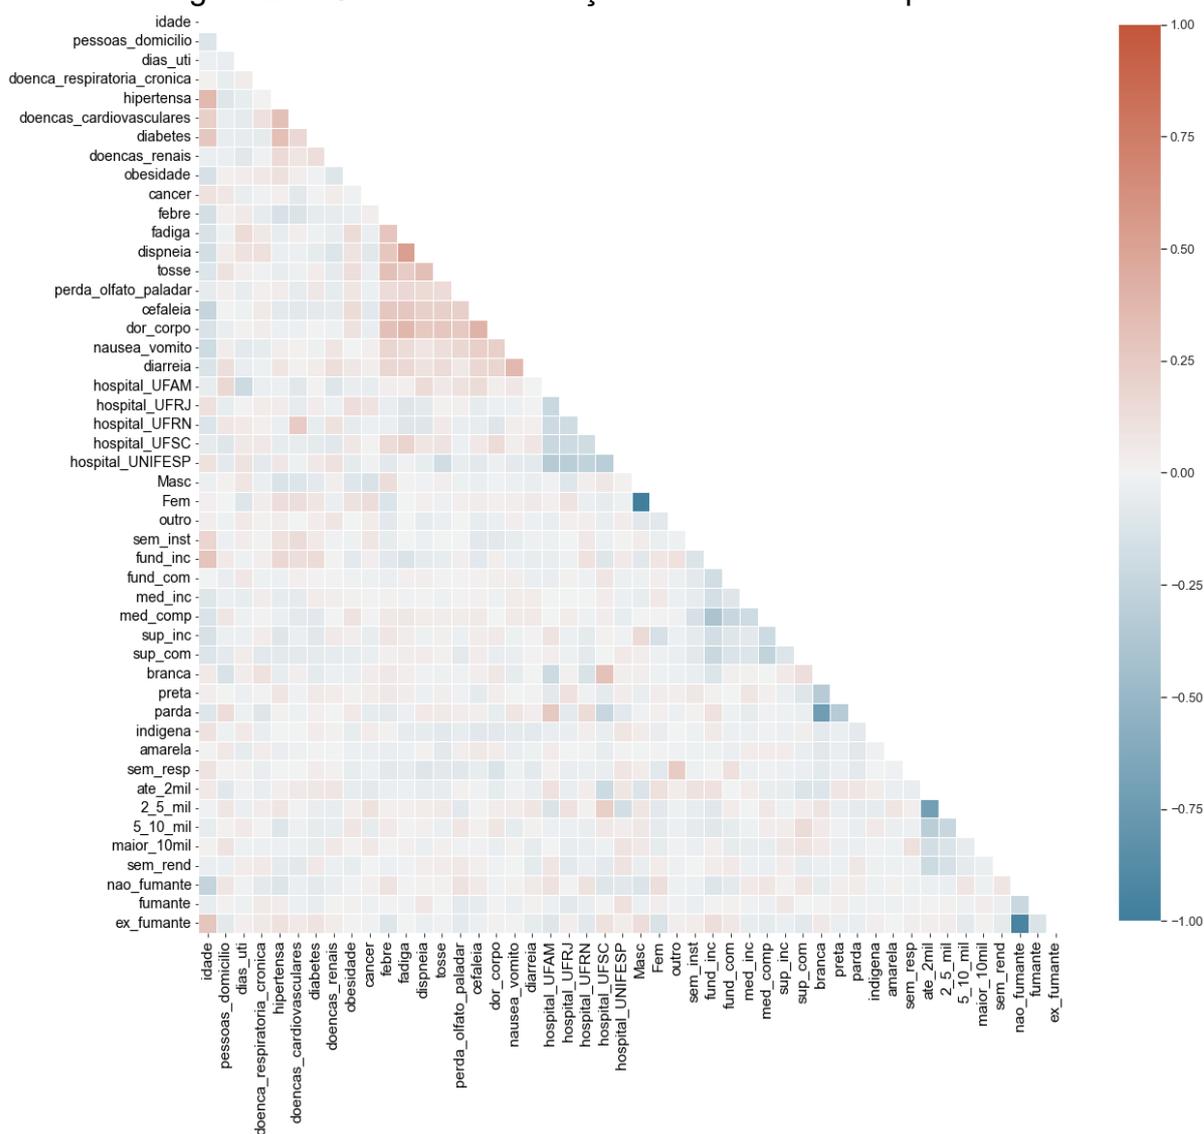
Figura 23 - Relação entre a variável doença respiratória crônica e UTI.



Fonte: Elaborado pela autora (2023).

Na Figura 24 é apresentado o gráfico de correlação de Pearson para observação das relações existentes entre as variáveis preditoras, em que vermelho indica maior correlação positiva, azul representa correlação negativa entre as variáveis e branco uma baixa correlação. Em relação às correlações, pode-se observar algumas variáveis que apresentam relação positiva entre elas: dispneia e fadiga, dor no corpo e cefaleia.

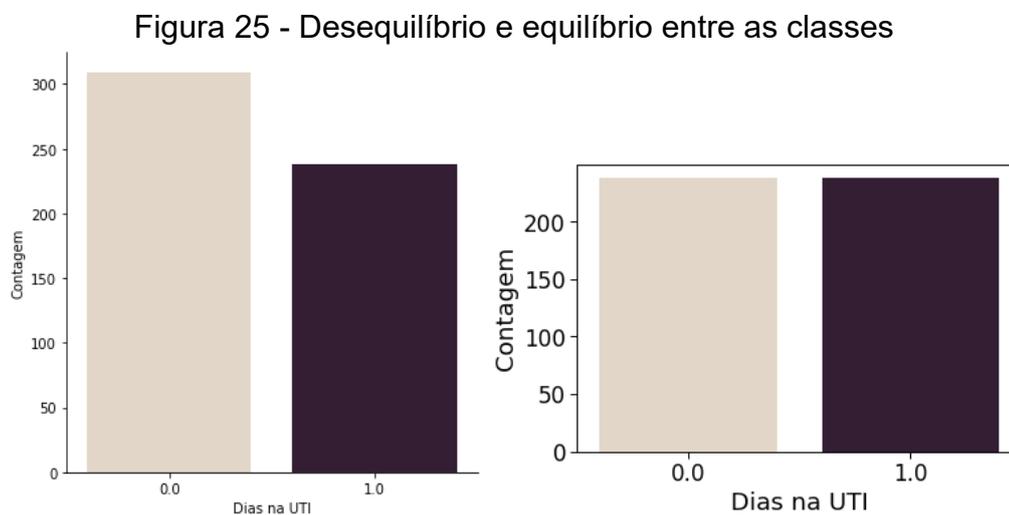
Figura 24 - Gráfico de correlação entre as variáveis preditoras.



Fonte: Cientista de dados e programador da pesquisa (2023).

Na etapa de modelagem dos dados, observou-se a existência de maior número de registros de pacientes com desfecho negativo para UTI (309 pacientes) em relação ao desfecho positivo para UTI (238 pacientes), conforme evidenciado no gráfico à esquerda da Figura 25. O desequilíbrio entre as classes pode influenciar na capacidade preditiva do modelo ao favorecer a aprendizagem para a classe com o maior número de registros. A sub amostragem, ou *undersampling* como é denominada em inglês, foi a técnica utilizada para realizar o equilíbrio entre as classes, misturando randomicamente os dados de cada uma das classes. Em seguida, é realizada a coleta das classes a partir do menor número de registros (desfecho positivo para UTI) até

ocorrer o balanceamento entre as classes, de acordo com gráfico demonstrado ao lado direito da Figura 25. A partir do balanceamento entre as classes, o grupo amostral que era composto por 547 pacientes passou para 476 pacientes Pradipta et al., 2022).



Fonte: Cientista de dados e programador da pesquisa (2023).

Os dados foram separados aleatoriamente em 75% (357 pacientes) dos dados para treinamento e 25% (119 pacientes) para teste da capacidade preditiva do modelo. As variáveis numéricas foram padronizadas removendo a média e escalonando em torno da variância unitária (Scikit Learn, 2022).

O desempenho de cada um dos algoritmos preditivos da internação de pacientes COVID-19 em UTI é apresentado na Tabela 7. Observa-se uma variação da área acima da curva de 0.585 até 0.668, em que a árvore de decisão atingiu a melhor performance preditora. A árvore de decisão foi parametrizada do seguinte modo: foi induzida a árvore binária, instituído o número mínimo de casos em galhos em 5 e a profundidade máxima das árvores em 12, além disso, não dividir subconjuntos menores que 7 e classificada para parar quando a maioria alcançava 99%.

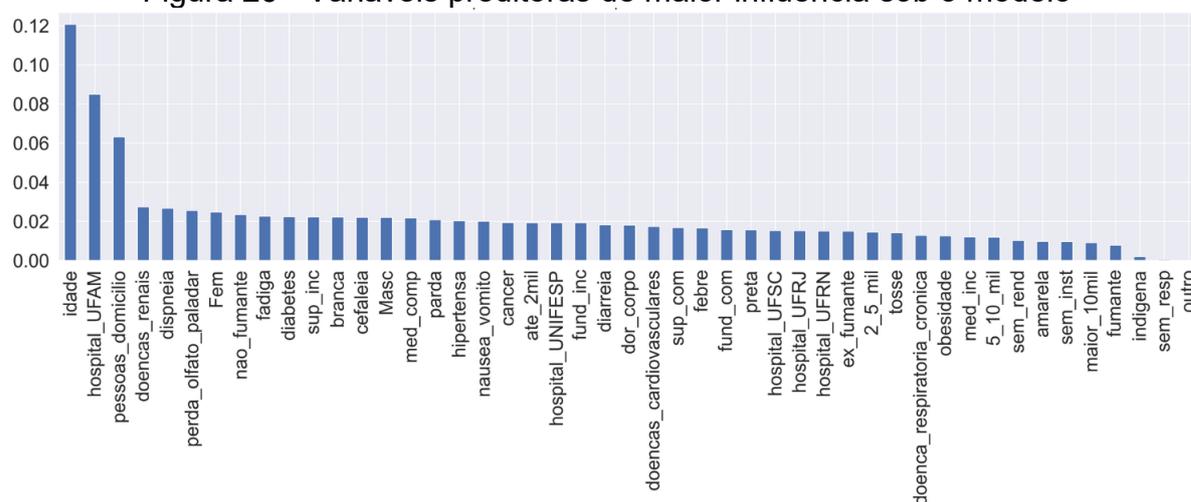
Tabela 7 - Desempenho dos algoritmos

Algoritmos	AUC	Sensibilidade	Especificidade
Árvore de decisão	0.668	0.633	0.669
Rede neural	0.666	0.622	0.673
Floresta aleatória	0.656	0.616	0.734
Regressão logística	0.638	0.618	0.692
<i>kNN</i>	0.632	0.605	0.673
<i>Naive Bayes</i>	0.623	0.592	0.640
SVM	0.615	0.580	0.572
<i>AdaBoost</i>	0.585	0.589	0.611

Fonte: Elaborado pela autora (2023).

Para o modelo de árvore de decisão, as variáveis preditoras que exerceram maior influência sob o modelo, são: idade, hospital vinculado à Universidade Federal do Amazonas e número de pessoas residentes no mesmo domicílio. Enquanto as demais variáveis exercem menor influência sob o modelo, conforme apresentado na Figura 26.

Figura 26 - Variáveis preditoras de maior influência sob o modelo

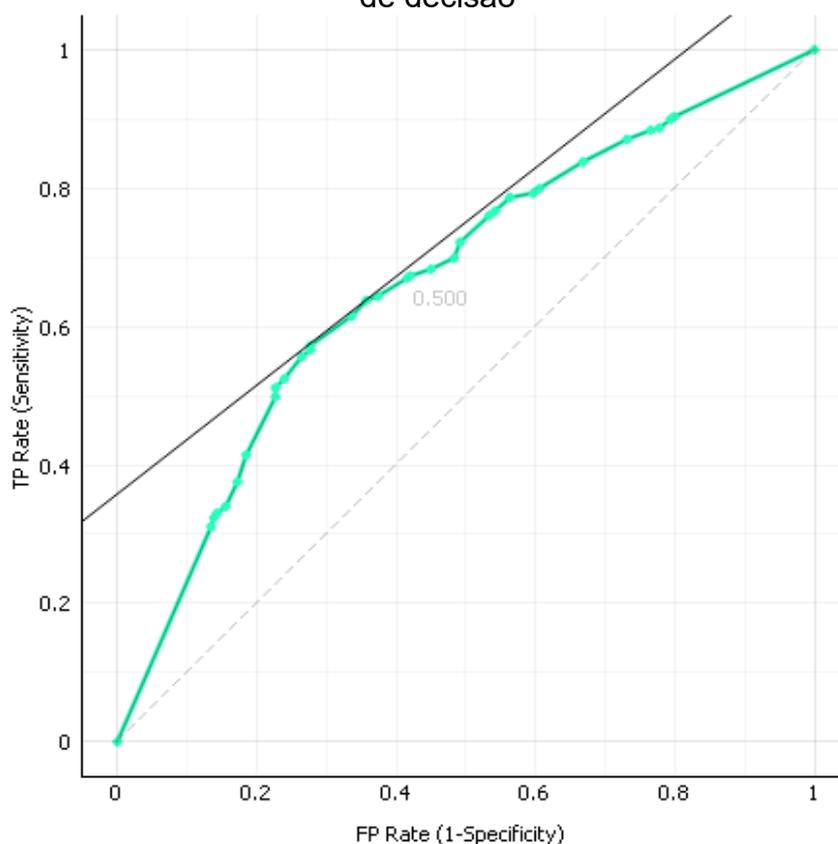


Fonte: Cientista de dados e programador da pesquisa (2023).

Nas Figuras 27 e 28 podem ser observadas as métricas da área acima da curva (Figura 27) e matriz de confusão (Figura 28) da árvore de decisão. Na matriz de confusão é possível observar que 207 pacientes o modelo categorizou como não iriam

para a UTI e de fato não foram, 139 pacientes foram classificados pelo modelo com probabilidade de irem para a UTI e realmente foram, por outro lado, 102 pacientes foram classificados como falsos positivos, ou seja, o modelo classificou como se os pacientes fossem para a UTI mas na verdade eles não foram e 99 pacientes o modelo classificou como não iriam para a UTI quando eles foram.

Figura 27 - Característica de Operação do Receptor (ROC) para o modelo de árvore de decisão



Fonte: Cientista de dados e programador da pesquisa (2023).

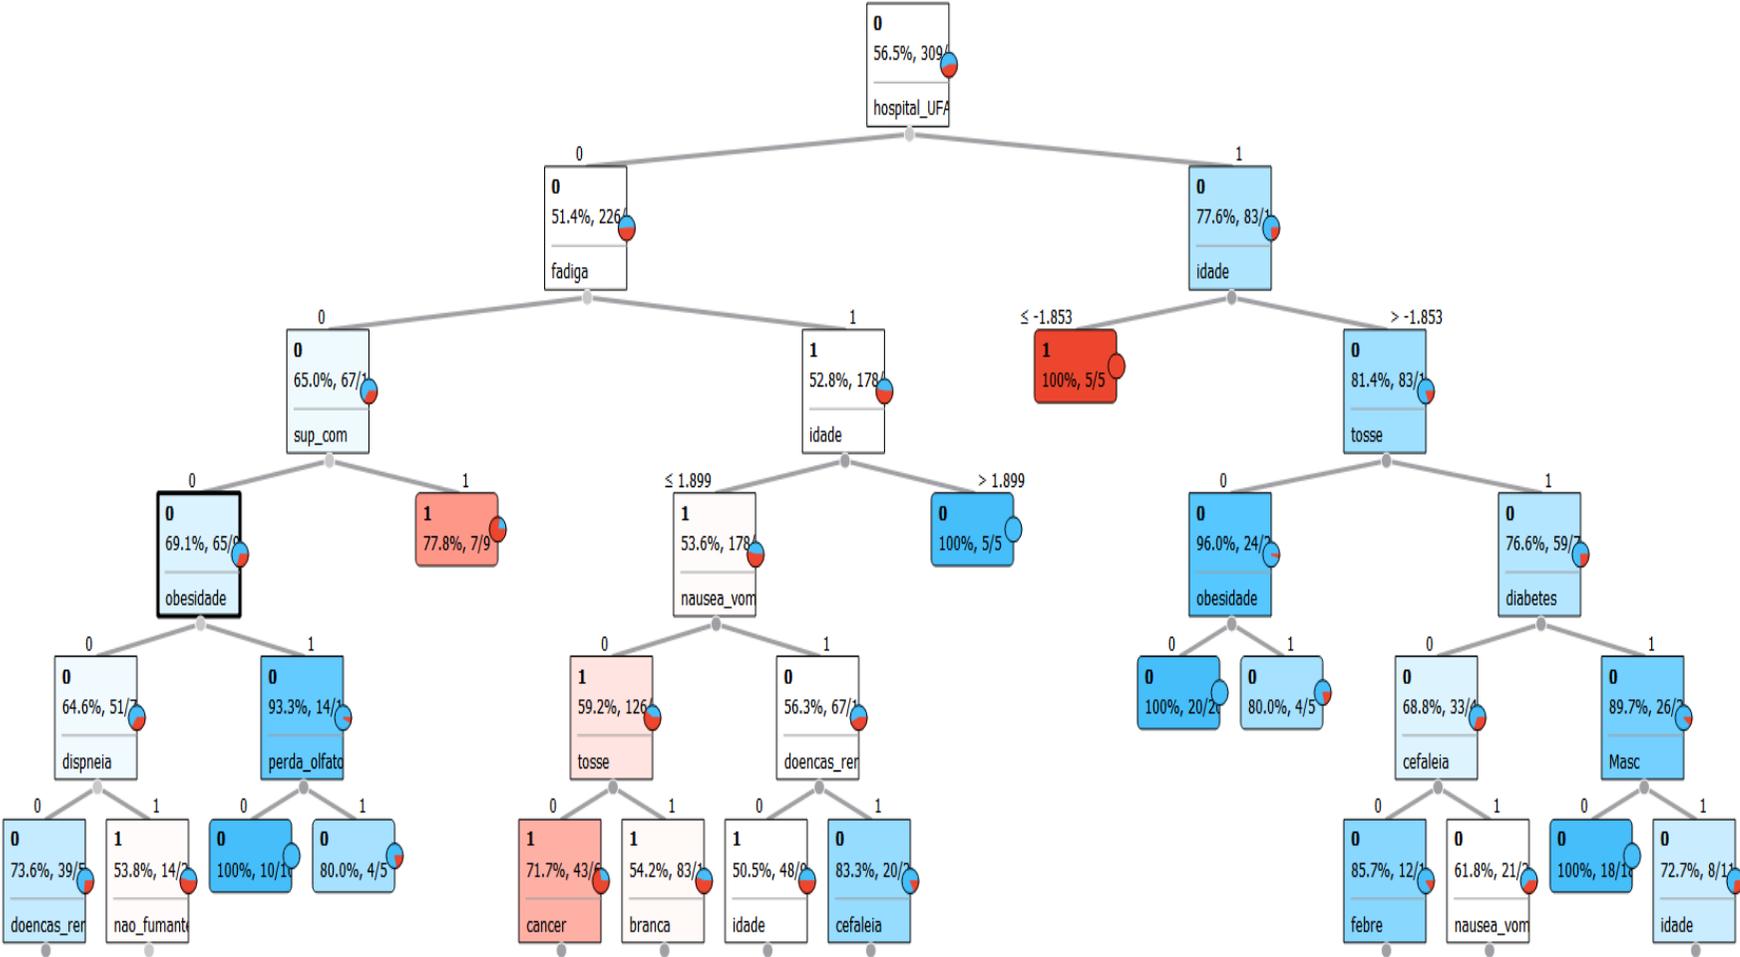
Figura 28 - Matriz de confusão para o modelo de árvore de decisão

		Predicted		$\Sigma$
		0	1	
Actual	0	207	102	309
	1	99	139	238
$\Sigma$		306	241	547

Fonte: Cientista de dados e programador da pesquisa (2023).

A Figura 29 apresenta como ocorreu a predição pela árvore de decisão até o nível 6.

Figura 29- Árvore de decisão



Fonte: Cientista de dados e programador da pesquisa (2023).

## DISCUSSÃO

Dos 08 modelos testados, a *AUC* variou de 0.585 a 0.668 e a árvore de decisão foi a que apresentou a melhor performance, este algoritmo é um dos mais elementares de aprendizado de máquina e, por esse motivo, facilita o entendimento do seu funcionamento completo. Na estrutura de uma árvore de decisão, cada nó significa um teste feito em um atributo. Os ramos, são os resultados dos testes e as suas folhas (nos) apresentam o rótulo de uma classe a partir da decisão do modelo. Esta divisão do conjunto de dados em subconjuntos é que leva ao aprendizado. O processo de divisão em subconjuntos é finalizado quando um nó apresenta valor igual ao da variável de interesse ou as divisões não adicionam mais valor à previsão. Portanto, a estrutura em forma de árvore estabelece caminhos ao dividir os dados em pequenos grupos, ou seja, funciona como um modelo de classificação e dentro de um conjunto de possibilidades prevê a classe correta daquela informação (Shukla; Maheshwari; Johri, 2021).

Após a identificação do modelo de árvore de decisão, a discussão acerca do comportamento da doença e da representatividade das variáveis em relação a variável de interesse, nos auxiliam na compreensão dos resultados apresentados pelos modelos de inteligência artificial. As variáveis apresentadas na Tabela 6 demonstram um equilíbrio entre os dados, tanto de pacientes que não foram para a UTI, quanto de pacientes que foram, o que pode estar relacionado às mudanças no cenário da pandemia de COVID-19, como o surgimento de novas variantes com biomarcadores clínicos diferenciados e a inclusão da variável vacinação agindo sobre a internação dos pacientes, uma vez que no período de coleta de dados, de abril a dezembro de 2021, alguns pacientes já haviam sido vacinados contra a doença.

Em relação à variável idade, a média de idade dos pacientes não internados em UTI foi de 56,06 anos e dos pacientes internados em UTI de 55,06 anos, ou seja, os pacientes internados em UTI nesse banco de dados são mais jovens do que os pacientes não internados em UTI. No início da pandemia, em abril de 2020, 40% dos pacientes internados em UTI eram pacientes com mais de 70 anos (Cohen *et al.*, 2020). No entanto, à medida que as taxas de vacinação foram aumentando, houve uma redução da idade média de internação. Um estudo realizado em um hospital da Espanha apontou que a média de idade dos pacientes internados em UTI antes da

imunização foi de 63,22 anos e de 58,88 após a imunização, o que representa uma diminuição de 4,34 anos em um intervalo de confiança de 95%. A média de idade reduz para 52,35 anos após a imunização de 10% da população e a porcentagem de pacientes com mais de 60 anos admitidos na UTI devido à COVID-19 caiu para menos de 50% desde que 17% da população havia sido vacinada (González-Castro *et al.*, 2022).

A vacinação é um fator decisivo para a gestão da pandemia com potencial para controle da doença e redução dos casos graves (González-Castro *et al.*, 2022; Moghadas *et al.*, 2020). A imunização reduz em até 65,6% as taxas de internação em UTI de pacientes vacinados contra a COVID-19 (Moghadas *et al.*, 2020). Em pacientes com o esquema vacinal completo também ocorre uma redução da probabilidade de uso de ventilador mecânico de 55,4% e 22,6% menor probabilidade de ir a óbito (Maltezou *et al.*, 2023).

Em relação às variáveis preditoras do modelo, ou seja, variáveis que mais exercem influência sobre o modelo, destaca-se a idade, internação no hospital universitário vinculado a Universidade Federal do Amazonas e o número de residentes no mesmo domicílio. Embora não exista um padrão entre os dados de idade conforme mencionado anteriormente, ainda assim o algoritmo identificou esta variável como a de maior importância para o modelo.

A variável preditora idade converge com uma pesquisa realizada na Espanha, em que a idade foi o preditor mais parcimonioso para internação em UTI dentre pacientes COVID-19, seguida de temperatura e frequência respiratória (Izquierdo; Ancochea; Soriano, 2020). Enquanto estudo realizado nos Estados Unidos identificou procalcitonina, lactato desidrogenase, proteína C reativa, saturação de oxigênio, ferritina e temperatura como variáveis preditoras de internação em UTI (Hou *et al.*, 2021). Entretanto, as variáveis procalcitonina, lactato desidrogenase, proteína C reativa e ferritina não foram consideradas no presente estudo, enquanto a presença ou ausência de dispneia e a temperatura, foram coletadas a partir do relato dos pacientes ou familiares. Outro estudo realizado nos Estados Unidos identificou frequência respiratória, leucócitos, linfócitos, pressão sanguínea diastólica, proteína C reativa, oximetria de pulso e em 7ª posição a idade enquanto variável preditora de internação em UTI (Cheng *et al.*, 2020).

As outras duas variáveis preditoras que mais influenciaram o modelo foram o número de pessoas em domicílio e internação no hospital universitário vinculado a Universidade Federal do Amazonas. Essas variáveis referem-se a características particulares do Brasil. Em relação a internação no hospital da UFAM conforme demonstrado na Figura 20 tiveram mais pacientes que não foram internados em UTI em relação aos pacientes que foram internados.

O Amazonas é o maior estado do Brasil em extensão territorial, distribuído em 1.559.168,12 km<sup>2</sup> e uma população de 4.144.597 habitantes e foi uma das cidades mais afetadas pela COVID-19 no Brasil. Os leitos de UTIs estavam concentrados apenas na capital, Manaus, contando com 1.24 leitos de UTI, tanto públicos quanto privados para cada 10.000 habitantes. O que pode ter limitado o acesso dos pacientes para tratamento dos casos graves de COVID-19, justamente pela dificuldade de transporte dos pacientes até os serviços de saúde, pelo acesso limitado a ventilador mecânico, hospitais e UTI's (Palamim; Marson, 2020; Pereira *et al.*, 2020).

Os achados do presente estudo associados aos resultados encontrados na literatura científica apontam que parece não existir uma padronização entre as variáveis preditoras de internação em UTI, já que os estudos analisam variáveis diferentes e algumas destas variáveis estão associadas a características locais. Embora os estudos utilizem diferentes variáveis, incluindo variáveis mais onerosas como biomarcadores laboratoriais, a *AUC* destes modelos não apresenta grandes variações. Por exemplo, no presente estudo, o melhor modelo (árvore de decisão) apresentou uma *AUC* de 69%. Na literatura científica, o modelo que identificou as variáveis preditoras idade, temperatura e frequência respiratória para probabilidade de internação em UTI, apresentou uma *AUC* de 76% (Izquierdo; Ancochea; Soriano, 2020). Enquanto o modelo que incluiu as seguintes variáveis preditoras: procalcitonina, lactato desidrogenase, proteína C reativa, saturação de oxigênio de pulso, ferritina e temperatura a *AUC* foi de 79% (Hou *et al.*, 2021). E o modelo que incluiu frequência respiratória, leucócitos, linfócitos, pressão sanguínea diastólica, proteína C reativa, oximetria de pulso e em 7° posição a idade apresentou uma *AUC* de 79,9% (Cheng *et al.*, 2020).

A seleção das variáveis corretas costuma melhorar o desempenho do modelo, é improvável que todas as variáveis de um banco de dados sejam úteis para a construção do modelo de inteligência artificial, ao contrário, variáveis redundantes

diminuem o potencial de generalização do modelo e conseqüentemente influenciam no resultado da predição. Dessa forma, o número de variáveis coletadas deve ser o necessário e muito bem refinados para realizar a predição com boa performance. Por esse motivo, devem ser removidas as variáveis desnecessárias, pois elas aumentam o custo da coleta de dados, o custo computacional e aumentam a complexidade do modelo. Por exemplo, um modelo que inclui uma variável resultado de exame de raio-x de tórax vai elevar os custos da coleta (Shukla; Maheshwari; Johri, 2021).

As variáveis preditoras identificadas no estudo são coletadas por enfermeiros durante a realização do histórico de enfermagem e outros sintomas e biomarcadores são identificados durante o exame físico do paciente. A coleta e análise destes biomarcadores clínicos e laboratoriais fornece informações que auxiliam na tomada de decisão do profissional enfermeiro para planejar e implementar intervenções de precisão a partir da identificação desses biomarcadores. Assim, a escolha de biomarcadores deve estar associada a hipóteses de intervenções de Enfermagem de Precisão e ocorrer de modo a apresentar uma ampla avaliação da condição de base do indivíduo e a partir da avaliação dos biomarcadores validar ou refutar a hipótese que levou à intervenção, baseada em evidências (Corwin; Ferranti, 2016).

O que remete a discussão anterior de que a inclusão da variável vacinação poderia ser uma variável de maior valor preditivo para este estudo. Além disso, não foram levadas em consideração as características regionais dos pacientes, uma vez que o estudo engloba pacientes de quatro regiões do Brasil. As características regionais da população como genética, contexto inserido e hábitos de vida podem ter influenciado no desempenho dos modelos. Não se evidenciou na literatura científica estudos multicêntricos que avaliem a capacidade de generalização de modelos de inteligência artificial.

## **CONCLUSÃO**

O algoritmo de árvore decisão apresentou a melhor performance preditiva para predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, tendo como métricas:  $AUC = 0.668$ , sensibilidade = 0.633 e especificidade = 0.669. As variáveis preditoras de maior importância para o modelo de árvore de decisão foram: hospital vinculado à Universidade Federal do Amazonas

e número de pessoas residentes no mesmo domicílio e parece não existir um consenso na literatura científica de quais seriam as variáveis preditoras de internação de pacientes infectados pela COVID-19 em UTI uma vez que as pesquisas anteriores analisaram variáveis diferentes e algumas destas delas, estão associadas a características locais e/ou regionais.

A identificação desse modelo, apresenta uma oportunidade de uso clínico, como uma ferramenta de apoio à tomada de decisão, ao indicar aos enfermeiros os pacientes que requerem avaliações mais frequentes, por meio do apontamento da probabilidade de internação em UTI. A identificação precoce de casos graves, auxilia na prevenção do rebaixamento do quadro e reduz o risco de mortalidade e uso de ventilação mecânica.

No entanto, a partir da dinamicidade da doença, como as mutações do vírus, com biomarcadores clínicos e laboratoriais diferenciados, é necessário o refinamento das variáveis preditivas e avaliações frequentes, para aumentar a capacidade preditiva do modelo de inteligência artificial. Dentre as fragilidades do estudo encontra-se o fato desta predição ter analisado unicamente os pacientes que sobreviveram a COVID-19 e que possuíam condições física, psicológica e cognitiva para responder ao questionário. Além disso, não foram coletadas informações referentes à condição vacinal dos pacientes e a vacinação é um fator decisivo para a gestão da pandemia, auxiliando no combate da doença e na redução dos casos graves. Desta forma, para estudos futuros, sugere-se a inclusão desses marcadores, partindo da hipótese de que poderiam melhorar as interações subsequentes do modelo.

## REFERÊNCIAS

ACOSTA, A. M. *et al.* Brazilian version of the care transitions measure: translation and validation. **Int Nurs Rev.**, v. 64, n. 3, p. 379-87, 2017. DOI: <https://doi.org/10.1111/inr.12326>

CHENG, F. Y. *et al.* Using Machine Learning to Predict ICU Transfer in Hospitalized COVID-19 Patients. **Journal of Clinical Medicine**, v. 9, n. 6, p. 1668, 1 jun. 2020. DOI: 10.3390/jcm9061668

COHEN, J.F. *et al.* COVID-19-Related Fatalities and Intensive-Care-Unit Admissions by Age Groups in Europe: A Meta-Analysis. **Front Med.**, v. 7, p. 560685, 14 jan. 2021. DOI: 10.3389/fmed.2020.560685

COLLINS, G. S. *et al.* Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): The TRIPOD statement. **BMC Medicine**, v. 13, n. 1, 6 jan. 2015. DOI: <https://doi.org/10.1186/s12916-014-0241-z>

COSTA, M. F. B. N. A. de *et al.* **Manual de coleta de dados para aplicação do Care Transitions Measure (CTM-15)**. Florianópolis: UFSC, 2022. Disponível em: <https://repositorio.ufsc.br/handle/123456789/238306>. Acesso em: 15 ago. 2023.

COVINO, M. *et al.* Predicting intensive care unit admission and death for COVID-19 patients in the emergency department using early warning scores. **Resuscitation**, v. 156, p. 84–91, 1 nov. 2020. DOI: 10.1016/j.resuscitation.2020.08.124

FU, M. R. *et al.* Precision health: A nursing perspective. **International Journal of Nursing Sciences**, v. 7, n. 1, p. 5, 10 jan. 2020. DOI: 10.1016/j.ijnss.2019.12.008

GONZÁLEZ-CASTRO, A. Impacto de la vacunación en los ingresos en una unidade de cuidados intensivos por COVID-19 en un hospital de tercer nivel. **Medicina Intensiva**, v. 46, n. 7, p. 406–407, 2022. DOI: 10.1016/j.medin.2021.08.002

HEIDARI, A. *et al.* Machine learning applications for COVID-19 outbreak management. **Neural Computing & Applications**, v. 34, p. 15313-15348, 10 jun. 2022. DOI: <https://doi.org/10.1007/s00521-022-07424-w>

HOU, W. *et al.* Machine learning predicts the need for escalated care and mortality in COVID-19 patients from clinical variables. **International Journal of Medical Sciences**, v. 18, n. 8, p. 1739–1745, 19 fev. 2021. DOI: 10.7150/ijms.51235

IZQUIERDO, J. L.; ANCOCHEA, J.; SORIANO, J. B. Clinical Characteristics and Prognostic Factors for Intensive Care Unit Admission of Patients With COVID-19: Retrospective Study Using Machine Learning and Natural Language Processing. **Journal of Medical Internet Research**, v. 22, n. 10, e21801, 1 out. 2020. DOI: 10.2196/21801

LOPES JÚNIOR, L. C. Personalized Nursing Care in Precision-Medicine Era: **SAGE Open Nursing**, v. 7, 9 dez. 2021a. DOI:10.1177/23779608211064713

LOPES JÚNIOR, L. C. The era of precision medicine and its impact on nursing: paradigm shifts? **Revista Brasileira de Enfermagem**, v. 74, n. 5, p. e740501, 28 jul. 2021b. DOI: <https://doi.org/10.1590/0034-7167.2021740501>

MA, X.; VERVOORT, D. Critical care capacity during the COVID-19 pandemic: Global availability of intensive care beds. **J Crit Care**, v. 58, p. 96-97, 2020. doi: 10.1016/j.jcrc.2020.04.012

MELO, A. L. S. F. de. **Manual de coleta de dados para aplicação do patient measure of safety (PMOS)**. Florianópolis: UFSC, 2022. Disponível em: <https://repositorio.ufsc.br/handle/123456789/238311>. Acesso em: 15 ago. 2023.

MELLO, J. F.; BARBOSA, S. F. F. Translation and transcultural adaptation of the Patient Measure of Safety (PMOS) questionnaire to Brazilian Portuguese. **Texto Contexto - enferm.**, v. 30, e20180322, 2021. DOI: <https://doi.org/10.1590/1980-265X-TCE-2018-0322>

MALTEZOU, H. C. *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. **Vaccine**, v. 41, n. 14, p. 2343-2348, 2023. DOI: [10.1016/j.vaccine.2023.01.067](https://doi.org/10.1016/j.vaccine.2023.01.067)

MOGHADAS, S. M. *et al.* The impact of vaccination on COVID-19 outbreaks in the United States. **medRxiv**, 30 nov. 2020. DOI: <https://doi.org/10.1101/2020.11.27.20240051>

PALAMIM, C.; MARSON, F. COVID-19 – The Availability of ICU Beds in Brazil during the Onset of Pandemic. **Annals of Global Health**, v. 86, n. 1, p. 100–101, 2020. DOI: [10.5334/aogh.3025](https://doi.org/10.5334/aogh.3025)

PEREIRA, R. H. M. *et al.* Geographic access to COVID-19 healthcare in Brazil using a balanced float catchment area approach. **Social Science & Medicine**, v. 273, 113773, Mar. 2021, 19 jul. 2020. DOI: [10.1016/j.socscimed.2021.113773](https://doi.org/10.1016/j.socscimed.2021.113773)

PRADIPTA, G. A. *et al.* Machine learning model for umbilical cord classification using combination coiling index and texture feature based on 2-D Doppler ultrasound images. **Health Informatics Journal**, v. 28, n. 1, p. 146045822210842, 29 jan. 2022. DOI: [10.1177/14604582221084211](https://doi.org/10.1177/14604582221084211)

SCIKIT LEARN. **sklearn.preprocessing.StandardScaler**: scikit-learn 1.3.0. 2023. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>. Acesso em: 28 mar. 2022.

SHUKLA, S.; MAHESHWARI, A.; JOHRI, P. Comparative Analysis of MI Algorithms & Stream Lit *Web Application*. **2021 3rd International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)**, Greater Noida, India, p. 175-180, 2021. DOI: [10.1109/ICAC3N53548.2021.9725496](https://doi.org/10.1109/ICAC3N53548.2021.9725496)..

TAYLOR, N. *et al.* Validation of the patient measure of safety (PMOS) questionnaire in Australian public hospitals. **Int J Qual Health Care**, v. 32, n. Suppl 1, p. 67-74, 2020. DOI: <https://doi.org/10.1093/intqhc/mzz097>

WEBER, L. A. F.; LIMA, M. A. D. S.; ACOSTA, A. M. Quality of care transition and its association with hospital readmission. **Aquichan**, v. 19, n. 4, e1945, 2019. DOI: <http://dx.doi.org/10.5294/aqui.2019.19.4.5>

YUAN, C. Precision Nursing: New Era of Cancer Care. **Cancer Nursing**, v. 38, n. 5, p. 333–334, 2015. DOI: [10.1097/NCC.0000000000000290](https://doi.org/10.1097/NCC.0000000000000290)

#### 5.4 ARTIGO 4 – *WEB APP* PARA PREDIÇÃO DA INTERNAÇÃO EM UNIDADE DE TERAPIA INTENSIVA POR COVID-19

A inovação tecnológica apresentada no artigo a seguir foi aprovada para publicação na Revista Brasileira de Enfermagem, conforme print do e-mail disponibilizado no Anexo C. A revista é classificada pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior no quadriênio de 2017-2020 como Qualis A4 para a área da enfermagem.

O Web App, denominado COVID-19 UTI PREDICTOR e descrito a seguir, foi registrado como programa de computador, no Departamento de Inovação (Sinova) da Universidade Federal de Santa Catarina e Instituto Nacional da Propriedade Intelectual (INPI) sob o número de registro INPI: 512023002623-9, conforme certificado de registro apresentado no Anexo D.

##### ***Web App* para predição da internação em Unidade de Terapia Intensiva por COVID-19**

##### ***Web App* for COVID-19 Intensive Care Unit admission prediction**

##### **Aplicación *Web* para la predicción del ingreso en la Unidad de Cuidados Intensivos mediante COVID-19**

#### **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:** Pesquisa aplicada de produção tecnológica com 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 apresentação dos resultados de pesquisa, pela facilidade no entendimento 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 admission of patients with COVID-19 in ICU. **Methods:** Applied research of technological production with Streamlit development from *Python*, considering the decision tree model that showed the best performance (*AUC* 0.668). **Results:** From the variables associated with Precision Nursing, Streamlit stratifies the patients admitted to the clinical units with a higher probability of admission to Intensive Care Unit, working as a decision support tool for health professionals. **Final Considerations:** The model's performance may have been influenced by the beginning of vaccination during the data collection period. However, the *Web App* via Streamlit proved to be a viable tool for presentation of research results, due to its ease of understanding by nurses and its potential to support clinical decision making.

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

## RESUMEN

**Objetivo:** Desarrollar una aplicación *Web* a partir de un modelo predictivo para estimar el riesgo de infección de pacientes con COVID-19 en IU. **Métodos:** Pesquisa aplicada de produção tecnológica com 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 de las variables asociadas a la Enfermería de Precisión, Streamlit estratifica los pacientes ingresados en las unidades clínicas con mayor probabilidad de ingreso en la Unidad de Cuidados Intensivos, funcionando como una herramienta de apoyo a la decisión para los profesionales de la salud. **Consideraciones Finales:** El rendimiento del modelo puede haber sido influenciado por el inicio de la vacunación en el período de coleta de datos, por lo tanto, la *Web App* a través de Streamlit se presenta como una herramienta versátil para la presentación de los resultados de la investigación, por la facilidad de comprensión de los enfermeros y por el potencial de apoyo a la decisión clínica.

**Descriptores:** Invenciones; Predicción; Inteligencia Artificial; COVID-19; Medicina de Precisión.

## INTRODUÇÃO

Os pacientes infectados pela COVID-19 apresentam evolução clínica variada da doença, com sinais e sintomas que variam desde quadros leves a forma moderada a grave 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 exigem cuidados em uma Unidade de Terapia Intensiva (UTI) (Cheng *et al.*, 2020; Covino *et al.*, 2020).

Existem alguns estudos que se propõem a desenvolver modelos de inteligência artificial para prever a probabilidade de pacientes infectados pela COVID-19 evoluírem para agravamento no quadro clínico e necessitarem de internação em UTI (Cheng *et al.*, 2020; Covino *et al.*, 2020; Aznar-Gimeno *et al.*, 2021). Essas tecnologias fornecem previsões estatísticas precisas que auxiliam na tomada de decisão dos profissionais da saúde (Gonçalves *et al.*, 2020). Entretanto, um dos desafios consiste na forma de disponibilização dos 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*, *Web App* que se utiliza de 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 (Streamlit, 2022). Não foram evidenciados, 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 COVID-19, em UTI.

Essas técnicas de inteligência artificial levam a melhorias no cuidado de Enfermagem e na atenção em saúde como um todo, tendo como referencial teórico a Enfermagem de Precisão, que auxilia provedores a personalizar o atendimento (Yuan, 2015). 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) (Yuan, 2015; Corwin; Ferranti, 2016; Menon *et al.*, 2019). 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 daquele indivíduo (Corwin; Ferranti, 2016).

O auxílio de ferramentas de precisão ajuda os profissionais de saúde a estratificarem os pacientes que demandam maior necessidade de atendimento personalizado. Ou seja, para identificação de pacientes com maior risco e, portanto, 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 (Kwong *et al.*, 2022; Rebêlo *et al.*, 2022).

## **OBJETIVO**

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

## **MÉTODO**

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 por uma solução imediata para a resolução de um problema atual (Pezzi *et al.*, 2020). *Web Apps* são ferramentas computacionais que vão desde simples páginas na *Web* a sites completos com funcionalidades especializadas e que processam uma série de informações. Dentre as funcionalidades, possibilita integração a bancos e o desenvolvimento de aplicações em determinada área (Pressman, Maxim; 2016).

O estudo faz parte da tese de doutorado intitulada: “Enfermagem de Precisão e Inteligência Artificial: biomarcadores para 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:

### **RECRUTAMENTO DE INFORMAÇÕES DOS PACIENTES**

Foram participantes do estudo 547 pacientes diagnosticados com COVID-19 que passaram por internação 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 via entrevista telefônica, nos meses de abril a dezembro de 2021, baseados na listagem disponibilizada pelos hospitais universitários. No primeiro contato, os pacientes eram convidados a participar do estudo a partir da leitura do Termo de Consentimento Livre e Esclarecido, quando o paciente aceitava participar da pesquisa era iniciada a gravação da entrevista e a aplicação do questionário *Care Transitions Measure* (CTM-15) que avalia a transição do cuidado hospitalar para o domicílio e o *Patient Measure Of Safety* (PMOS) que avalia a segurança do paciente no contexto hospitalar. Em seguida, era aplicado o questionário sociodemográfico estruturado para caracterização dos pacientes, o qual foi utilizado, neste estudo, e as respostas foram registradas na plataforma *Googleforms*® (Acosta *et al.*, 2017; Mello, Barbosa, 2021).

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

Foram analisadas 23 variáveis associadas a Enfermagem de Precisão: informações sociodemográficas dos pacientes como: idade; gênero; grau de instrução e raça. No que se refere a biomarcadores clínicos: 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; diarreia. Em relação a fenótipo (hábitos de vida) foi analisada uma única variável: histórico de tabagismo. Referente a epigenética (determinantes sociais e contexto): renda familiar e quantas pessoas residem no seu domicílio. Foram excluídas do estudo as variáveis: município de residência, dias de internação e uso de ventilação mecânica pela

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, removendo a média e escalonando em torno da variância unitária. As demais variáveis foram consideradas categóricas e transformadas em valores binários 0 ou 1, por meio da técnica *one-hot encoding*, para que os dados pudessem ser modelados como valores numéricos. Após realizadas as técnicas para padronização da informação, foram imputados os valores ausentes para completar o banco de dados.

O banco de dados estava composto por 309 pacientes que passaram pela UTI e 238 não haviam passado. Essa discrepância entre as classes pode facilitar o aprendizado da classe com o maior número de registros. Por esse motivo, utilizou-se da técnica de subamostragem *undersampling* para realizar o equilíbrio entre as classes. Por meio de uma seleção randômica, são misturados os dados das duas classes e, posteriormente, é realizado um novo agrupamento a partir da classe com o menor número de registros, restando 476 pacientes (Pradipta *et al.*, 2022).

## TREINAMENTO E VALIDAÇÃO DOS MODELOS

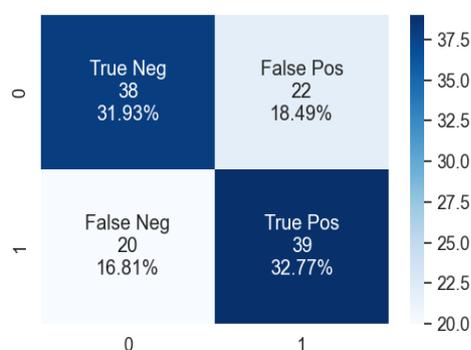
Os dados foram divididos randomicamente em 75% (357 pacientes) para treinamento do modelo e 25% (119 pacientes) para teste. Foram testados os seguintes modelos de inteligência artificial: rede neural, *AdaBoost*, regressão logística, floresta aleatória, *K Nearest Neighbor*, *Naive Bayes*, *Support Vector 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 interações e de grupos em que a amostra foi dividida de forma aleatória, nesse caso, cinco interações e cinco grupos. A cada interação, quatro grupos são destinados para treino e um grupo destinado para teste, na próxima interação esses grupos são alterados e a acurácia final é calculada a partir da média das acurácias das interações (Valerio Netto; Berton; Takahata, 2021). A *AUC* refere-se a 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) (11). As três primeiras variáveis que mais influenciaram na decisão do modelo incluíram a idade, estar internado no hospital da Universidade Federal do Amazonas e o número de pessoas residentes no mesmo domicílio, seguido das demais variáveis.

A sensibilidade é avaliada por meio do cálculo do número de pacientes classificados como verdadeiro positivo, dividido pelo verdadeiro positivo mais o falso negativo, avaliando o percentual de resultados positivos do modelo. Enquanto a especificidade caracteriza-se pelo cálculo do número de pacientes classificados como verdadeiro positivo dividido pelo número de verdadeiro negativo mais o falso positivo e avalia a capacidade do modelo de detectar resultados negativos (Valerio Netto; Berton; Takahata, 2021).

A Figura 30 apresenta a matriz de confusão evidenciada 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. Evidencia-se 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 procurou-se diminuir 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 apresenta probabilidade de ir para a UTI, pelas implicações práticas dessa classificação.

Figura 30 - Matriz de confusão



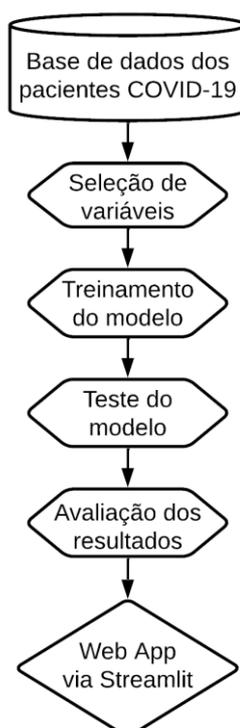
Fonte: Cientista de dados e programador da pesquisa (2023).

## DESENVOLVIMENTO DO *WEB APP*

A equipe de desenvolvimento do *Web App* foi composta por uma equipe multidisciplinar de três pessoas: o desenvolvedor foi um engenheiro de software e duas enfermeiras, ambas especialistas em gestão em saúde, uma delas com 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 escreveu o código fonte no *Python*, onde foi realizada a padronização das variáveis, treinamento e testes dos modelos para posterior desenvolvimento do *Streamlit*, também criou o repositório no GitHub.

A Figura 31 apresenta o fluxograma de construção do *Web App*, evidenciando o caminho percorrido desde a base de dados, treinamento e teste dos modelos até a construção do *Web App*.

Figura 31 - Fluxograma de construção do *Web App*



Fonte: Elaborado pela autora (2023).

O trabalho foi desenvolvido em linguagem de programação *Python*, onde foram identificados os melhores modelos e, posteriormente, foi executado o *Streamlit*. Inicialmente, foram executados o comando '*streamlit run*' 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 customizado com textos, gráficos, figuras, tabelas e o que mais for necessário para ajustar a aplicação de acordo com as necessidades. Essas mudanças podem ser feitas, alterando o código-fonte e salvando o arquivo de origem. O *Streamlit* detecta as alterações e pergunta se você gostaria de aplicá-las. Isso permite uma interação rápida entre o código que está sendo descrito e a visualização da aplicação (Streamlit, 2022).

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

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, CAAE 38912820.3.1001.0121 e parecer de aprovação número 4.347.463. Ainda em relação aos princípios éticos da pesquisa com seres humanos, aos participantes do estudo, foi lido e obtido o Termo de Consentimento Livre e Esclarecido de todos os participantes da pesquisa.

## **RESULTADOS DA INOVAÇÃO TECNOLÓGICA**

O *Web App* foi desenvolvido com base na árvore de decisão que foi o melhor modelo de inteligência artificial identificado. A descrição do código e a execução do *Streamlit* foi efetuada no *Python*. Conforme evidenciado na Figura 32 apresenta-se a interface do usuário ao acessar o *Web App*.

Figura 32 - Página inicial do *Web App*

**Aplicativo web desenvolvido para defesa de tese de doutorado.**

**Greici Capellari**

Criado por Lincoln Moura e Greici Capellari

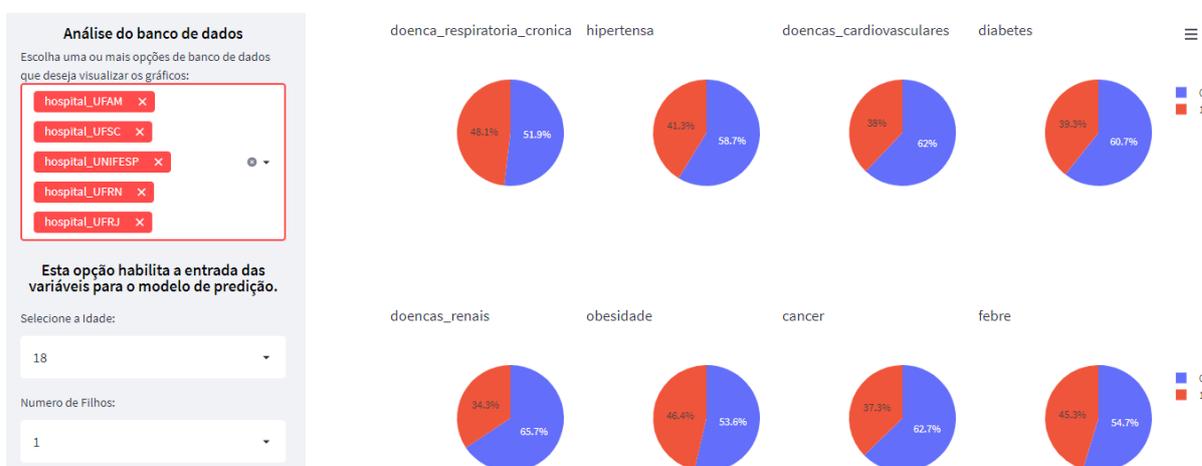
Emails para contato: +

Esta aplicação de inteligência artificial tem como objetivo fornecer uma ferramenta de análise preditiva para auxílio a tomada de decisão dos profissionais. No lado esquerdo da tela, insira as variáveis referente as informações clínicas do paciente e verifique o resultado do banco de dados da COVID.

Análise do banco de dados

Fonte: Elaborado pela autora (2023).

Na Figura 33 é possível visualizar uma apresentação visual e interativa das variáveis associadas a Enfermagem de Precisão. Por exemplo: sinais e sintomas da COVID-19, informações demográficas e doenças prévias dos pacientes que compõem o banco de dados. A exploração dos dados possibilita que o enfermeiro possa conhecer quais são as características dos pacientes que compõem o estudo. Também podem ser exploradas as características por hospital, ou mais de um hospital, conforme comando selecionado pelo profissional.

Figura 33 - Exploração visual e interativa do banco de dados no *Web App*

Fonte: Elaborado pela autora (2023).

Agora vamos a um exemplo de aplicação de uso da ferramenta. O enfermeiro do plantão, na unidade de internação COVID-19, recebe um paciente do sexo masculino, 37 anos, branco, ensino superior completo, dois filhos, renda familiar entre R\$ 5.000 e R\$ 10.000 reais, não apresenta comorbidades, com os seguintes sintomas: falta de ar, tosse e febre e 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, insere as variáveis no *Web App* e visualiza uma previsão da probabilidade de internação em UTI do referido paciente.

Conforme exemplo apresentado anteriormente, o enfermeiro poderia utilizar-se do *Web App* como uma ferramenta de apoio a sua tomada de decisão. No menu ao lado esquerdo da aplicação, é possível inserir as variáveis relacionadas a Enfermagem de Precisão que caracterizam o perfil clínico de um paciente novo internado, conforme demonstrado na Figura 34.

Figura 34 - Inserção dos dados clínicos do paciente no *Web App*

**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 instrucao do paciente:

sup\_com

Preencha a raca 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

Fonte: Elaborado pela autora (2023).

A predição é, então, submetida, a partir do conhecimento do modelo de inteligência aprendido do banco de dados de pacientes anteriores, ele classifica a probabilidade desse novo paciente ir ou não para a UTI. A Figura 35 apresenta um

resultado com 68% de probabilidade de não necessitar de internação em UTI, com a acurácia do modelo de 64,7%.

Figura 35 - Simulação de caso em que o paciente apresenta baixa probabilidade de ir para UTI

### Conclusão do resultado apontado pelo modelo:

De acordo com o modelo o paciente possui baixa probabilidade de ir para UTI!

### Estatísticas do resultado:

Acurácia Total do Modelo Utilizado	Resultado a Predição	Probabilidade de ser negativo:	Probabilidade de ser positivo:
64,7 %	0	0.68 ↑ %	0.32 ↓ -%

Fonte: Elaborado pela autora (2023).

Por outro lado, a Figura 36 apresenta uma classificação pelo modelo de predição em que o paciente apresenta uma probabilidade de 68% de chance de ir para a UTI, classe 1. Nas classificações em que o resultado apresenta probabilidade de ir para UTI o resultado aparece em uma escala de cores vermelha, ao contrário, quando o paciente possui baixa probabilidade de ir para a UTI, a escala de cor é verde.

Figura 36 - Simulação de caso em que o paciente apresenta alta probabilidade de ir para uti

### Conclusão do resultado apontado pelo modelo:

De acordo como modelo o paciente possui alta probabilidade de ir para UTI!

### Estatísticas do resultado:

Acurácia Total do Modelo Utilizado	Resultado a Predição	Probabilidade de ser negativo:	Probabilidade de ser positivo:
64,7 %	1	0.32 ↓ -%	0.68 ↑ %

Fonte: Elaborado pela autora (2023).

Além da probabilidade de ir ou não para UTI, após a predição, a ferramenta também demonstra as variáveis que tiveram maior importância para o modelo e a matriz de confusão.

O desenvolvimento da inovação tecnológica mostrou-se como uma solução para apresentação dos resultados de uma pesquisa proveniente de uma tese de doutorado, demonstrando as potencialidades do *Web App*, construído via Streamlit, para realizar predições sobre a 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 armazenamento de informações referentes às simulações realizadas no *Web App*, o que pode ser utilizado no futuro para melhoria da performance preditiva do modelo. A captação dessas informações aponta as mudanças que podem acontecer no comportamento da doença ao longo do tempo.

## DISCUSSÃO

Dos 08 modelos testados, a árvore de decisão foi o que apresentou a melhor *AUC* (0.668), parametrizada da seguinte forma: foi induzida a árvore binária, instituído o número mínimo de casos em galhos em 5 e a profundidade máxima das árvores em 12, além disso, parametrizada para não dividir subconjuntos menores que 7. Foi classificada para parar quando a maioria alcançava 99%. A parametrização de árvores com a profundidade máxima de 12 evita o *overfitting*, ou sobre ajuste que pode acontecer em árvores com muitos ramos.

A árvore de decisão é caracterizada por nós (folhas) e ramos, cada nó significa um teste feito em um atributo e os ramos são os resultados dos testes, assim, uma quantidade de dados segue por um ramo e a outra por outro. Desta forma, o nó seguinte receberá uma quantidade menor de amostras que o nó anterior (Shukla; Maheshwari; Johri, 2021). A árvore de decisão é um dos algoritmos de aprendizado de máquina mais elementares, o que contribui para o entendimento dos profissionais de saúde já que podem ser exploradas a interpretabilidade e explicabilidade do modelo, sendo evidente a forma como o modelo classifica os pacientes.

Além disso, acredita-se que a performance do modelo de árvore de decisão (*AUC* 0.668) pode estar relacionada a uma importante variável que não foi considerada neste estudo: a situação vacinal dos pacientes, uma vez que a vacinação reduz os casos graves de COVID-19, podendo chegar a 65,6% de redução de internação em UTI em pacientes vacinados (Moghadas *et al.*, 2020). Em pacientes com o esquema vacinal completo a probabilidade de internação em UTI reduz em 48,8%, a redução de probabilidade de usar ventilador mecânico é ainda menor chegando a 55,4% e apresentam 22,6% menor probabilidade de ir a óbito. Os pacientes vacinados permanecem hospitalizados por períodos mais curtos enquanto os pacientes não vacinados, ficam afastados do trabalho por períodos maiores (Maltezo *et al.*, 2023).

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 disponibilização do melhor modelo de inteligência artificial para uso dos profissionais. Um estudo retrospectivo realizado na China, incluiu 385 participantes para 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, desenvolveram um modelo de inteligência artificial para avaliar o risco de um possível vazamento no pós-operatório de pacientes submetidos à vertebroplastia percutânea (Li *et al.*, 2021).

Outra pesquisa de coorte retrospectiva, inclui 103 meninos diagnosticados com válvula de uretra posterior. Os pacientes foram avaliados por 5,7 anos, já 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 (Kwong *et al.*, 2022). A aplicação foi mencionada como uma ferramenta simples, fácil de usar e intuitiva para enfermeiros e profissionais da saúde (Streamlit, 2022). Aplicações móveis, como é o exemplo do *Web App* permitem a conexão entre um dispositivo móvel ao conteúdo baseado na *Web* por meio de um navegador especificamente planejado para determinada finalidade, neste caso predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva (Pressman; Maxim, 2016).

Entretanto, se tratando de um *Web App* preditivo para uso na prática clínica é necessário o cuidado para não solicitar muitas informações do paciente (variáveis), uma vez que não é viável ao profissional inserir uma grande quantidade de variáveis em uma situação que demanda uma rápida tomada de decisão por parte da equipe (Gonçalves *et al.*, 2020). Nesse sentido, foram consideradas 23 variáveis preditoras, as quais são rapidamente coletadas na prática clínica.

A construção da aplicação foi viabilizada devido a junção de conhecimentos entre as áreas de engenharia e saúde. Nesse caso em específico, os conhecimentos de enfermeiras, compartilhando informações científicas, teóricas e práticas relacionadas à atuação na área de saúde para delineamento do aplicativo com um engenheiro de software, que desenvolveu a parte de código. Essa complementaridade de sabedores direciona o projeto, uma vez que promove o encontro de necessidades dos profissionais de saúde, por meio da experiência do usuário, as possibilidades das tecnologias. Essas estratégias favorecem a adoção da ferramenta na prática profissional da enfermagem (Gonçalves *et al.*, 2020).

Nesse sentido, o *Web App* tem como potencialidade o desenvolvimento de habilidades relacionadas à construção de softwares por profissionais de enfermagem e saúde. Também, na medida em que passam a utilizá-la se torna 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 a necessidade de capacitação profissional em saúde digital e a resistência dos próprios profissionais de saúde para a construção desse tipo de projeto.

## CONCLUSÃO

O algoritmo de árvore decisão apresentou a melhor *AUC* (0.668) para predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, por esse motivo 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 novos estudos com a análise dessas variáveis.

O *Web App* via *Streamlit* facilita a construção e funcionamento de ferramentas em relação a outros métodos, facilitando o entendimento dos profissionais de saúde e apresentando potencial como uma ferramenta de apoio à tomada de decisão clínica. O que 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 engenheiro de software, favoreceu a junção de habilidades, onde cada profissional contribui 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, conseqüentemente, na performance do modelo.

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

## REFERÊNCIAS

ACOSTA, A. M. *et al.* Brazilian version of the care transitions measure: translation and validation. **Int Nurs Rev.**, v. 64, n. 3, p. 379-87, 2017. DOI: <https://doi.org/10.1111/inr.12326>

AZNAR-GIMENO, R. *et al.* A clinical decision *Web* to predict ICU admission or death for patients hospitalised with COVID-19 using machine learning algorithms. **Int. J. Environ. Res. Public Health**, v. 18, n. 6, p. 8677, 2021. DOI: <https://doi.org/10.3390/ijerph18168677>

CHENG, F. Y. *et al.* Using Machine Learning to Predict ICU Transfer in Hospitalized COVID-19 Patients. **Journal of Clinical Medicine**, v. 9, n. 6, p. 1668, 1 jun. 2020. DOI: [10.3390/jcm9061668](https://doi.org/10.3390/jcm9061668)

CORWIN, E. J.; FERRANTI, E. P. Integration of biomarkers to advance precision nursing interventions for family research across the life span. **Nursing outlook**, v. 64, n. 4, p. 292–298, 2016. DOI: [10.1016/j.outlook.2016.04.007](https://doi.org/10.1016/j.outlook.2016.04.007)

COVINO, M. *et al.* Predicting intensive care unit admission and death for COVID-19 patients in the emergency department using early warning scores. **Resuscitation**, v. 156, p. 84–91, 1 nov. 2020. DOI: 10.1016/j.resuscitation.2020.08.124

GONÇALVES, L. S. *et al.* Implantação de algoritmo de inteligência artificial para detecção da sepse. **Revista Brasileira de Enfermagem**, v. 73, n. 3, p. e20180421, 9 abr. 2020. DOI: <https://doi.org/10.1590/0034-7167-2018-0421>

GONZÁLEZ-CASTRO, A. Impacto de la vacunación en los ingresos en una unidade de cuidados intensivos por COVID-19 en un hospital de tercer nivel. **Medicina Intensiva**, v. 46, n. 7, p. 406–407, 2022. DOI: 10.1016/j.medin.2021.08.002

KWONG, J. C. *et al.* Posterior Urethral Valves Outcomes Prediction (PUVOP): a machine learning tool to predict clinically relevant outcomes in boys with posterior urethral valves. **Pediatric Nephrology**, v. 37, n. 5, p. 1067-1074, 2022. DOI: 10.1007/s00467-021-05321-3

LI, W. *et al.* Machine Learning Applications for the Prediction of Bone Cement Leakage in Percutaneous Vertebroplasty. **Frontiers in Public Health**, v. 9, p. 812023, 10 dez. 2021. DOI: <https://doi.org/10.3389/fpubh.2021.812023>

MALTEZOU, H. C. *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. **Vaccine**, v. 41, n. 14, p. 2343-2348, 2023. DOI: 10.1016/j.vaccine.2023.01.067

MELLO, J. F.; BARBOSA, S. F. F. Translation and transcultural adaptation of the Patient Measure of Safety (PMOS) questionnaire to Brazilian Portuguese. **Texto Contexto - enferm.**, v. 30, e20180322, 2021. DOI: <https://doi.org/10.1590/1980-265X-TCE-2018-0322>

MENON, U. *et al.* Precision health research and implementation reviewed through the conNECT framework. **Nursing outlook**, v. 67, n. 4, p. 302–310, jul./ago. 2019. DOI: <https://doi.org/10.1016/j.outlook.2019.05.010>

MOGHADAS, S. M. *et al.* The impact of vaccination on COVID-19 outbreaks in the United States. **medRxiv**, 30 nov. 2020. DOI: <https://doi.org/10.1101/2020.11.27.20240051>

PEZZI, M. DA C. S. *et al.* Desenvolvimento de um Protótipo Instrucional para Procedimentos Técnicos em Centro de Material e Esterilização. **Texto & Contexto - Enfermagem**, v. 29, p. 1–11, 2020. DOI: <https://doi.org/10.1590/1980-265X-TCE-2019-0047>

PRADIPTA, G. A. *et al.* Machine learning model for umbilical cord classification using combination coiling index and texture feature based on 2-D Doppler ultrasound images. **Health Informatics Journal**, v. 28, n. 1, p. 146045822210842, 29 jan. 2022. DOI: 10.1177/14604582221084211

PRESSMAN, R.S.; MAXIM, B. R. **Engenharia de software**: uma abordagem profissional. 8° ed. Porto Alegre: Mc Graw Hill; 2016.

REBÊLO, V. C. N. *et al.* Post Covid-19 Syndrome: case study. **Research, Society and Development**, v. 11, n. 2, p. e43811225969–e43811225969, 31 jan. 2022. DOI: 10.33448/rsd-v11i2.25969

SHUKLA, S.; MAHESHWARI, A.; JOHRI, P. Comparative Analysis of ML Algorithms & Stream Lit *Web Application*. **2021 3rd International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)**, Greater Noida, India, p. 175-180, 2021. DOI: 10.1109/ICAC3N53548.2021.9725496..

STREAMLIT. **The fastest way to build and share data apps**. 2023. Disponível em: <https://streamlit.io/>. Acesso em: 4 abr. 2022.

VALERIO NETTO, A.; BERTON, L.; TAKAHATA, A. K. **Ciência de dados e inteligência artificial na área da saúde** Editora dos Editores. São Paulo: Editora dos editores, 2021.

YUAN, C. Precision Nursing: New Era of Cancer Care. **Cancer Nursing**, v. 38, n. 5, p. 333–334, 2015. DOI: 10.1097/NCC.0000000000000290

## 6 CONCLUSÃO

O presente estudo buscou responder às questões norteadoras propostas, quais sejam: Qual é o atual estado da arte sobre Enfermagem de Precisão? Quais são as variáveis preditoras da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva segundo os fundamentos teóricos da Enfermagem de Precisão? Qual é o modelo de inteligência artificial que apresenta a melhor performance para predição da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva?

E, do mesmo modo, alcançou os objetivos: Aplicar algoritmos de inteligência artificial para identificação de variáveis preditoras relacionados à Enfermagem de Precisão: biomarcadores clínicos (sinais e sintomas, comorbidades), epigenética (contexto de vida) e fenótipo (hábitos de vida) para predição da admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva e, a partir da identificação do melhor modelo, desenvolver um Web App para estimar o risco de internação de pacientes com COVID-19 em Unidade de terapia Intensiva e os objetivos específicos: 1) Analisar a produção científica acerca da Enfermagem de Precisão; 2) Identificar variáveis preditoras, aplicar e comparar algoritmos de aprendizado de máquina para predição da admissão de pacientes internados e contaminados pela COVID-19 em Unidade de Terapia Intensiva na cidade de Florianópolis/SC, a partir do referencial teórico da Enfermagem de Precisão; 3) Identificar variáveis preditoras e desenvolver um modelo de inteligência artificial para prever a admissão de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, a partir do referencial teórico da Enfermagem de Precisão, em cinco hospitais universitários brasileiros que foram referência para o atendimento e, 4) Desenvolver um Web App a partir do modelo com a melhor performance preditiva para estimar o risco de internação de pacientes com COVID-19 em UTI.

A efetivação do alcance dos objetivos resultou na composição de quatro artigos: 1) “Enfermagem de Precisão: Revisão integrativa da literatura”; 2) “Predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva na cidade de Florianópolis/SC”; 3) “Predição de admissões na Unidade de Terapia Intensiva de pacientes com COVID-19 em cinco hospitais universitários do Brasil” e 4) “Web App para predição da internação em Unidade de Terapia Intensiva

por COVID-19". O artigo 1, apresentado na fundamentação teórica, responde ao primeiro questionamento e ao objetivo 1. Os artigos 2 e 3 responderam a segunda e terceira questão de pesquisa e os objetivos 2 e 3 da pesquisa.

As variáveis preditoras de maior influência no projeto piloto foram: internação hospitalar, raça e dor de garganta e para a pesquisa multicêntrica foram: idade, internação no hospital universitário da Universidade Federal do Amazonas e número de pessoas residentes no domicílio. A enfermagem atua diretamente na identificação desses biomarcadores clínicos por meio da coleta de dados no histórico de enfermagem, exames físicos e laboratoriais. A identificação dos mecanismos subjacentes que estão por trás das doenças e de situações de agravamento dos quadros fornece informações que auxiliam na tomada de decisão do profissional enfermeiro para planejar e implementar intervenções de precisão que contribuem para a gestão do cuidado em enfermagem.

Os melhores modelos de inteligência artificial para predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva foram rede neural com uma *AUC* (0.917), sensibilidade (0.861) e especificidade (0.825) e para a pesquisa multicêntrica foi a árvore de decisão com uma *AUC* (0.668), sensibilidade (0.633) e especificidade (0.669). Observa-se que houve uma diminuição da capacidade preditora dos modelos diretamente relacionada à dinamicidade do curso evolutivo da COVID-19 e da evolução das formas de combate à doença. Desde o descobrimento da doença houve o surgimento de novas variantes, medicamentos passaram a ser indicados para a doença e vacinas foram desenvolvidas, bem como o auxílio tecnológico no combate à pandemia.

As novas variantes tiveram como características sintomas diferenciados do começo da pandemia, assim as variáveis que capturamos como produto do cuidado rotineiro também mudam. Desta forma, algumas associações nos dados antigos foram quebradas e variáveis determinadas como bons preditores podem não ser mais úteis na construção de modelos de predição. Estas mudanças tornam a geração de dados não estacionária, em que a distribuição de valores dos dados muda ao longo do tempo. Assim, as associações que mantêm os dados também mudam ao longo do tempo, o que significa que não podemos combinar todos os dados com dados mais recentes sem uma avaliação cuidadosa.

Sendo assim, conclui-se a importância de bons dados em saúde, ou seja, dados padronizados, completos, estruturados e com a inclusão de variáveis representativas para a criação de bons modelos em saúde. Diante deste cenário, a enfermagem é uma profissão com papel crucial na coleta de dados dos pacientes, o cuidado rotineiro inclui a realização de anamnese; verificação de sinais vitais, exames laboratoriais e registro destas informações no prontuário do paciente.

Por fim, ao definir prioridade entre falsos positivos e falsos negativos, para esse modelo procurou-se diminuir 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 apresenta probabilidade de ir para a UTI, pelas implicações práticas dessa classificação.

Desta forma, ao finalizar este trabalho confirma-se a tese:

**É possível prever o desfecho de internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, aplicando algoritmos de inteligência artificial que analisam a complexidade das relações e interações das variáveis preditoras disponíveis, fundamentadas no referencial teórico da Enfermagem de Precisão e contribuir para a gestão do cuidado de enfermagem, fornecendo suporte a tomada de decisão e contribuindo para um cuidado mais preciso.**

### **Contribuições do estudo para a área da enfermagem e saúde**

Este é o primeiro estudo a levantar o estado da arte acerca dos conceitos de Enfermagem de Precisão, desde o surgimento do tema, até os dias atuais. Também é uma pesquisa pioneira ao relacionar as variáveis de estudo a fundamentação teórica da Enfermagem de Precisão e, além disso, aplicá-los com técnicas de inteligência artificial. Desta forma, o estudo pode servir de modelo para o delineamento de pesquisas futuras e a condução de projetos no que tange a Enfermagem de Precisão, informática em enfermagem, inteligência artificial e dados em saúde.

Os *softwares low code* empregados no presente estudo, como o *Orange Data Mining* e *Knime Analytics Platform* podem servir como ponto de partida para o desenvolvimento de aplicações de inteligência artificial.

O presente estudo evidenciou a próxima e importante relação que a enfermagem desempenha no que se refere à coleta de dados em saúde. Por isso, a

importância de melhorarmos ainda mais a atuação de enfermeiros no cenário de dados em saúde, com padronização de coleta de dados, criação de modelos e sistemas que contribuam para a geração de informação a partir dos dados e conseqüentemente para a tomada de decisões em saúde, uma vez que se visualiza o potencial da enfermagem para trabalhar com os dados produzidos e avançar na construção do conhecimento no que se refere a informática em enfermagem.

### **Recomendações**

- **Evolução dos modelos**

Recomendação a evolução dos modelos no sentido de agregar mais dados para retreinar o modelo de acordo com a evolução da coleta de dados; identificar o momento em que os modelos precisam ser retreinados; automatizar o processo de coleta de dados das variáveis por meio de dados estruturados no prontuário do paciente; desenvolver novas técnicas para melhoria dos resultados e evoluir os meios de utilização e gerenciamento dos modelos.

- **Banco de dados**

A formação de um banco de dados nacional, a partir da integração de dados de sistemas de saúde (prontuários eletrônicos) e hábitos de vida das pessoas (vestíveis) pode contribuir para a geração de informações que auxiliam nas tomadas de decisões em saúde.

Se tratando especificamente da COVID-19, uma coleção centralizada de dados de pacientes em nível nacional será benéfica para futuras pesquisas de inteligência artificial para desenvolver estratégias preditivas, diagnósticas e terapêuticas contra a COVID-19 e pandemias semelhantes, que possam vir a ocorrer no futuro.

- **Interoperabilidade**

As políticas governamentais como a Política Nacional de Informação e Informática em Saúde e a Estratégia de Saúde Digital são fundamentais para o avanço tecnológico na área da saúde, essencialmente no que se refere à interoperabilidade entre as informações. As ferramentas como Web App e softwares em saúde deveriam estar integradas ao prontuário eletrônico do paciente para que fossem de fácil acesso

aos envolvidos no cuidado, também para fornecimento de informação quando esta fosse necessária a tomada de decisão.

- **Pesquisa**

Em relação às pesquisas futuras, sugere-se investigações nas quatro áreas que englobam a Enfermagem de Precisão: prevenção, diagnóstico, tratamento/intervenções e reabilitação. Acredita-se que a aplicação de medicamentos em exatidão possa desenvolver-se como uma subárea da Enfermagem de precisão e a enfermagem é a profissão que realiza a diluição e administração de medicamentos. A adequada administração da terapêutica medicamentosa influencia no sucesso do tratamento e no curso evolutivo da doença.

Ainda para estudos futuros, a inclusão de outras variáveis que possam ser representativas para o que se pretende predizer como: exames laboratoriais, esquema vacinal contra COVID-19 e informações genéticas. Também podem ser desenvolvidas pesquisas futuras para predizer a capacidade funcional dos pacientes no pós-covid-19 e estratificar os pacientes com maior probabilidade de necessitar de cuidados de reabilitação, por exemplo, fisioterapia.

As técnicas de inteligência artificial empregadas aqui também podem ser replicadas para outras patologias, inclusive para Doenças e Agravos Não Transmissíveis, como diabetes mellitus, doenças cardiovasculares e doenças respiratórias crônicas. Sugere-se a identificação de variáveis preditoras e a construção de modelos preditivos para identificação precoce de agravamento dos quadros clínicos. Neste contexto, outros modelos podem ser desenvolvidos com base neste conhecimento, mas tendo como base novos pressupostos.

- **Capacitação profissional**

É premente a discussão sobre a formação e capacitação de enfermeiros para atuação na saúde digital. Destaca-se o diferencial de enfermeiros com conhecimentos na área clínica, como genética; na área de *data science*, como coleta de dados, construção e manipulação de grandes bancos de dados e, na área de desenvolvimento de *softwares* em saúde. A participação de enfermeiros contribui para o desenvolvimento de tecnologias voltadas para as reais necessidades dos profissionais de saúde, pacientes e gestores.

### **Limitações da pesquisa**

O presente estudo apresentou algumas limitações no que tange:

- ✓ A predição da internação em UTI no artigo 3 ocorreu somente com dados de pacientes que sobreviveram à internação por COVID-19.
- ✓ Não foram analisadas informações genéticas dos pacientes no artigo 3;
- ✓ Não foram realizadas análises estratificadas levando em consideração as características regionais dos pacientes, uma vez que o estudo engloba pacientes de quatro regiões do Brasil. As características regionais da população como genética, contexto inserido e hábitos de vida podem ter influenciado no desempenho dos modelos.

Por estes motivos, recomenda-se a generalização desses achados com cautela, uma vez que os modelos foram desenvolvidos em um determinado contexto, com determinados pressupostos. Ou seja, os modelos aqui apresentados possuem aplicabilidade em um cenário determinado com pacientes específicos.

### **Divulgação do conhecimento científico**

As autoras mantiveram o compromisso com a divulgação do conhecimento científico e à medida que a tese foi escrita, os resultados dos estudos foram compartilhados com a comunidade científica. O artigo 2, intitulado “Predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva na cidade de Florianópolis/SC” foi apresentado como resultado parcial da presente tese no Congresso Brasileiro de Informática em Saúde em 2021 e recebeu destaque entre os cinco melhores trabalhos apresentados na edição do evento, conforme apresentado no Anexo B. O mesmo manuscrito está em processo de avaliação em um período da área de informática em saúde classificado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior no quadriênio de 2017-2020 como Qualis A4 para a área da enfermagem.

Em 2022 publicaram o editorial intitulado “Enfermería de precisión: una aliada para potenciar la gestión del cuidado” na Revista Avances em Enfermería conforme página inicial do editorial apresentada no Anexo E. No ano de 2023, as autoras publicaram o artigo intitulado: “Assistente virtual: ferramenta para coprodução em saúde no enfrentamento à COVID-19” na Revista Texto e Contexto Enfermagem no

ano de 2023 de acordo com o Anexo F. Este artigo não fez parte do relatório de tese apresentado, no entanto, demonstra outra possibilidade de aplicação das ferramentas de inteligência artificial, neste caso o processamento de linguagem natural no enfrentamento à COVID-19 e faz parte de um projeto paralelo a este estudo.

A inovação tecnológica apresentada no artigo 4, intitulado “*Web App* para predição da internação em Unidade de Terapia Intensiva por COVID-19” foi aprovado para publicação na Revista Brasileira de Enfermagem, categorizada como Qualis A4 para a área da Enfermagem na avaliação do quadriênio de 2017-2020 pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, conforme print de aceite da revista apresentado no Anexo C. O Web App, denominado COVID-19 UTI PREDICTOR, foi registrado como programa de computador no INPI:512023002623-9, conforme certificado de registro apresentado no Anexo D.

De acordo com a Instrução Normativa 02/PEN/2021 pelo menos um dos manuscritos que compuseram os resultados da pesquisa, não deve ter sido submetido ou publicado antes da aprovação da tese pela banca examinadora. Por este motivo, o artigo 3, intitulado “Predição de admissões na Unidade de Terapia Intensiva de pacientes com COVID-19 em cinco hospitais universitários do Brasil” será submetido após a entrega do trabalho.

## REFERÊNCIAS

- ACOSTA, A. M. *et al.* Brazilian version of the care transitions measure: translation and validation. **Int Nurs Rev.**, v. 64, n. 3, p. 379-87, 2017. DOI: <https://doi.org/10.1111/inr.12326>
- ANVISA. Agência Nacional de Vigilância Sanitária. **COVID-19 coronavírus**. 2023. Disponível em: <https://www.gov.br/anvisa/pt-br/assuntos/paf/coronavirus>. Acesso em: 23 maio 2023.
- AL-HASHIMI, M.; HAMDAN, A. Artificial Intelligence and Coronavirus COVID-19: Applications, Impact and Future Implications. *In*: Alareeni, B., Hamdan, A., ELGEDAWY, I. (ed.). *The Importance of New Technologies and Entrepreneurship in Business Development: In the Context of Economic Diversity in Developing Countries*. **Lecture Notes in Networks and Systems**, v. 194, p. 830–843, 2021. DOI: [https://doi.org/10.1007/978-3-030-69221-6\\_64](https://doi.org/10.1007/978-3-030-69221-6_64)
- ALIMADADI, A. *et al.* Artificial intelligence and machine learning to fight covid-19. **Physiological Genomics**, v. 52, n. 4, p. 200–202, 1 abr. 2020. DOI: <https://doi.org/10.1152/physiolgenomics.00029.2020>
- AMER, A. Y. A. *et al.* Vital Signs Prediction for COVID-19 Patients in ICU. **Sensors**, v. 21, n. 23, 1 dez. 2021. DOI: <https://doi.org/10.3390/s21238131>
- AZNAR-GIMENO, R. *et al.* A clinical decision web to predict ICU admission or death for patients hospitalised with COVID-19 using machine learning algorithms. **Int. J. Environ. Res. Public Health**, v. 18, n. 6, p. 8677, 2021. DOI: <https://doi.org/10.3390/ijerph18168677>
- BITENCOURT, J. V. de O. V. *et al.* Protagonismo do enfermeiro na estruturação e gestão de uma unidade específica para COVID-19. **Texto & Contexto - Enfermagem**, v. 29, p. 1–11, 31 ago. 2020. DOI: <https://doi.org/10.1590/1980-265X-TCE-2020-0213>
- BOURGONJE, A. R. *et al.* Angiotensin-converting enzyme 2 (ACE2), SARS-CoV-2 and the pathophysiology of coronavirus disease 2019 (COVID-19). **J Pathol.**, v. 251, n. 3, p. 228-248, jul. 2020. DOI: [10.1002/path.5471](https://doi.org/10.1002/path.5471).
- BRAGAZZI, N. L. *et al.* How big data and artificial intelligence can help better manage the covid-19 pandemic. **International Journal of Environmental Research and Public Health**, v. 17, n. 9, p. 3176, 2 maio 2020. DOI: [10.3390/ijerph17093176](https://doi.org/10.3390/ijerph17093176).
- BRASIL. Ministério da Saúde. **Estratégia de Saúde Digital para o Brasil 2020-2028**. Brasília: Ministério da Saúde, 2020a. Disponível em: [https://bvsms.saude.gov.br/bvs/publicacoes/estrategia\\_saude\\_digital\\_Brasil.pdf](https://bvsms.saude.gov.br/bvs/publicacoes/estrategia_saude_digital_Brasil.pdf). Acesso em: 12 fev. 2022
- BRASIL. Ministério da Saúde. **Portaria GM/MS nº 1.768, de 30 de julho de 2021**. Altera o Anexo XLII da Portaria de Consolidação GM/MS nº 2, de 28 de setembro de 2017, para dispor sobre a Política Nacional de Informação e Informática em Saúde

(PNIIS). Brasília: Ministério da Saúde, 2021. Disponível em: <https://www.in.gov.br/en/web/dou/-/portaria-gm/ms-n-1.768-de-30-de-julho-de-2021-335472332>. Acesso em: 12 fev. 2022.

BRASIL. Objetivos de Desenvolvimento Sustentável. **Nações Unidas**, 2022. Disponível em: <https://brasil.un.org/pt-br/sdgs>. Acesso em: 12 fev. 2022.

BRASIL. Presidência da República. **Lei Nº 13.709, de 14 de Agosto de 2018**. Lei Geral de Proteção de Dados Pessoais (LGPD). Brasília: Presidência, 2018. Disponível em: [http://www.planalto.gov.br/ccivil\\_03/\\_ato2015-2018/2018/lei/l13709.htm](http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm). Acesso em: 11 abr. 2022.

BRASIL. Programa Genomas vai ajudar na prevenção e tratamento de doenças na população brasileira. **Brasil Genomas**. 2020. Disponível em: <https://www.gov.br/pt-br/noticias/saude-e-vigilancia-sanitaria/2020/10/programa-genomas-vai-ajudar-na-prevencao-e-tratamento-de-doencas-na-populacao-brasileira>. Acesso em: 14 fev. 2022.

CASTRO, R. Vacinas contra a Covid-19: o fim da pandemia? **Physis: Revista de Saúde Coletiva**, v. 31, n. 1, p. 2021, 12 abr. 2021. DOI: <https://doi.org/10.1590/S0103-73312021310100>

CAVALCANTE, R. B. *et al.* Panorama de definição e implementação da Política Nacional de Informação e Informática em Saúde. **Cadernos de Saúde Pública**, v. 31, n. 5, p. 960–970, 20 jun. 2015. DOI: <https://doi.org/10.1590/0102-311X00095014>

CHENG, F. Y. *et al.* Using Machine Learning to Predict ICU Transfer in Hospitalized COVID-19 Patients. **Journal of Clinical Medicine**, v. 9, n. 6, p. 1668, 1 jun. 2020. DOI: 10.3390/jcm9061668

CHENG, J. *et al.* Factors influencing nurses' behavioral intention toward caring for COVID-19 patients on mechanical ventilation: A cross-sectional study. **PLOS ONE**, v. 16, n. 11, p. e0259658, 1 nov. 2021. DOI: <https://doi.org/10.1371/journal.pone.0259658>

COHEN, J.F. *et al.* COVID-19-Related Fatalities and Intensive-Care-Unit Admissions by Age Groups in Europe: A Meta-Analysis. **Front Med.**, v. 7, p. 560685, 14 jan. 2021. DOI: 10.3389/fmed.2020.560685

COLLINS, G. S. *et al.* Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): The TRIPOD statement. **BMC Medicine**, v. 13, n. 1, 6 jan. 2015. DOI: <https://doi.org/10.1186/s12916-014-0241-z>

CORWIN, E. J.; FERRANTI, E. P. Integration of biomarkers to advance precision nursing interventions for family research across the life span. **Nursing outlook**, v. 64, n. 4, p. 292–298, 2016. DOI: 10.1016/j.outlook.2016.04.007

COSTA, M. F. B. N. A. de *et al.* **Manual de coleta de dados para aplicação do Care Transitions Measure (CTM-15)**. Florianópolis: UFSC, 2022. Disponível em: <https://repositorio.ufsc.br/handle/123456789/238306>. Acesso em: 15 ago. 2023.

COVINO, M. *et al.* Predicting intensive care unit admission and death for COVID-19 patients in the emergency department using early warning scores. **Resuscitation**, v. 156, p. 84–91, 1 nov. 2020. DOI: 10.1016/j.resuscitation.2020.08.124

CUOCOLO, R. *et al.* Machine Learning in oncology: A clinical appraisal. **Cancer Letters**, v. 481, p. 55-62, 1 jul. 2020. Acesso em: 11 mar. 2021. DOI: 10.1016/j.canlet.2020.03.032

FERNEDA, E. Neural networks and its application in information retrieval systems. **Ciencia da Informacao**, v. 35, n. 1, p. 25–30, 2006. DOI: <https://doi.org/10.1590/S0100-19652006000100003>

FLORIANOPOLIS. Secretaria Municipal de Saúde. Covidômetro: o controle em nossas mãos. **Prefeitura de Florianópolis**, 2023. Disponível em: <https://covidometrofloripa.com.br/>. Acesso em: 23 mai. 2023.

FOUND, S. A.; TSIGAS, E.; REN, D.; BARMADA, M. M. Associating Symptom Phenotype and Genotype in Preeclampsia. **Biological research for nursing**, v. 20, n. 2, p. 126–136, mar. 2018. DOI: 10.1177/1099800417754140

FU, M. R. *et al.* Precision health: A nursing perspective. **International Journal of Nursing Sciences**, v. 7, n. 1, p. 5, 10 jan. 2020. DOI: 10.1016/j.ijnss.2019.12.008

GONÇALVES, L. S. *et al.* Implantação de algoritmo de inteligência artificial para detecção da sepse. **Revista Brasileira de Enfermagem**, v. 73, n. 3, p. e20180421, 9 abr. 2020. DOI: <https://doi.org/10.1590/0034-7167-2018-0421>

GONZÁLEZ-CASTRO, A. Impacto de la vacunación en los ingresos en una unidade de cuidados intensivos por COVID-19 en un hospital de tercer nivel. **Medicina Intensiva**, v. 46, n. 7, p. 406–407, 2022. DOI: 10.1016/j.medin.2021.08.002

HEIDARI, A. *et al.* Machine learning applications for COVID-19 outbreak management. **Neural Computing & Applications**, v. 34, p. 15313-15348, 10 jun. 2022. DOI: <https://doi.org/10.1007/s00521-022-07424-w>

HICKEY, K. T. *et al.* Precision Health: Advancing Symptom & Self-Management Science. **Nursing outlook**, v. 67, n. 4, p. 462-475, 1 jul. 2019. DOI: 10.1016/j.outlook.2019.01.003

HODSON, R. Precision medicine. **Nature**, v. 537, n. 7619, p. S49–S49, 7 set. 2016. DOI: <https://doi.org/10.1038/537S49a>

HOU, W. *et al.* Machine learning predicts the need for escalated care and mortality in COVID-19 patients from clinical variables. **International Journal of Medical Sciences**, v. 18, n. 8, p. 1739–1745, 19 fev. 2021. DOI: 10.7150/ijms.51235

IELAPI, N. *et al.* Precision Medicine and Precision Nursing: The Era of Biomarkers and Precision Health. **Int J Gen Med.**, v. 13, p. 1705-171, dez. 2020. DOI: 10.2147/IJGM.S285262.

IŞIK, M. T.; YILDIRIM, G. Individualized care perceptions and moral distress of intensive care nurses. **Nursing in Critical Care**, v. 28, n. 2, 2023. DOI: 10.1111/nicc.12715

IZQUIERDO, J. L.; ANCOCHEA, J.; SORIANO, J. B. Clinical Characteristics and Prognostic Factors for Intensive Care Unit Admission of Patients With COVID-19: Retrospective Study Using Machine Learning and Natural Language Processing. **Journal of Medical Internet Research**, v. 22, n. 10, e21801, 1 out. 2020. DOI: 10.2196/21801

JIANG, F. *et al.* Review of the Clinical Characteristics of Coronavirus Disease 2019 (COVID-19). **Journal of General Internal Medicine**, v. 35, n. 5, p. 1545-1549, 1 maio 2020. DOI: 10.1007/s11606-020-05762-w

JOHNS HOPKINS. COVID-19 Dashboard  
by the Center for Systems Science and Engineering (CSSE) at Johns Hopkins University (JHU). **Coronavirus Resource Center**. 2023. Disponível em: <https://coronavirus.jhu.edu/map.html>. Acesso em: 23 mai. 2023.

KEOGH, S. *et al.* Implementation and evaluation of short peripheral intravenous catheter flushing guidelines: A stepped wedge cluster randomised trial. **BMC Medicine**, v. 18, n. 252, p. 1–11, 30 set. 2020. DOI: <https://doi.org/10.1186/s12916-020-01728-1>

KILIC, A. Artificial Intelligence and Machine Learning in Cardiovascular Health Care. **The Annals of Thoracic Surgery**, v. 109, n. 5, p. 1323–1329, 1 maio 2020. DOI: 10.1016/j.athoracsur.2019.09.042

KWONG, J. C. *et al.* Posterior Urethral Valves Outcomes Prediction (PUVOP): a machine learning tool to predict clinically relevant outcomes in boys with posterior urethral valves. **Pediatric Nephrology**, v. 37, n. 5, p. 1067-1074, 2022. DOI: 10.1007/s00467-021-05321-3

LAKE, M. A. What we know so far: COVID-19 current clinical knowledge and research. **Clinical Medicine**, v. 20, n. 2, p. 124-127, 2020. DOI: 10.7861/clinmed.2019-coron

LANCELEY, A. *et al.* Ovarian Cancer Follow-up: A Preliminary Comparison of 2 Approaches. **International Journal of Gynecologic Cancer**, v. 27, p. 59-68, 2017.

LI, Z. *et al.* Analysis of risk factors of diabetes peripheral neuropathy in type 2 diabetes mellitus and nursing intervention. **Exp Ther Med.**, v. 20, n. 6, p. 127, 2020. DOI: 10.3892/etm.2020.9257

LI, W. *et al.* Machine Learning Applications for the Prediction of Bone Cement Leakage in Percutaneous Vertebroplasty. **Frontiers in Public Health**, v. 9, p. 812023, 10 dez. 2021. DOI: <https://doi.org/10.3389/fpubh.2021.812023>

LOPES JÚNIOR, L. C. Personalized Nursing Care in Precision-Medicine Era: **SAGE Open Nursing**, v. 7, 9 dez. 2021a. DOI:10.1177/23779608211064713

LOPES JÚNIOR, L. C. The era of precision medicine and its impact on nursing: paradigm shifts? **Revista Brasileira de Enfermagem**, v. 74, n. 5, p. e740501, 28 jul. 2021b. DOI: <https://doi.org/10.1590/0034-7167.2021740501>

MA, X.; VERVOORT, D. Critical care capacity during the COVID-19 pandemic: Global availability of intensive care beds. **J Crit Care**, v. 58, p. 96-97, 2020. doi: 10.1016/j.jcrc.2020.04.012

MACHHI, J. *et al.* The Natural History, Pathobiology, and Clinical Manifestations of SARS-CoV-2 Infections. **J Neuroimmune Pharmacology**, v. 15, n. 3, p. 359–386, 1 set. 2020. DOI: 10.1007/s11481-020-09944-5

MAGUNIA, H. *et al.* Machine learning identifies ICU outcome predictors in a multicenter COVID-19 cohort. **Critical Care**, v. 25, n. 295, 1 dez. 2021. DOI: <https://doi.org/10.1186/s13054-021-03720-4>

MALTEZOU, H. C. *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. **Vaccine**, v. 41, n. 14, p. 2343-2348, 2023. DOI: 10.1016/j.vaccine.2023.01.067

MELO, A. L. S. F. de. **Manual de coleta de dados para aplicação do patient measure of safety (PMOS)**. Florianópolis: UFSC, 2022. Disponível em: <https://repositorio.ufsc.br/handle/123456789/238311>. Acesso em: 15 ago. 2023.

MELLO, J. F.; BARBOSA, S. F. F. Translation and transcultural adaptation of the Patient Measure of Safety (PMOS) questionnaire to Brazilian Portuguese. **Texto & Contexto – Enfermagem**, v. 30, e20180322, 2021. DOI: <https://doi.org/10.1590/1980-265X-TCE-2018-0322>

MENDES, K. D. S.; SILVEIRA, R. C. DE C. P.; GALVÃO, C. M. Revisão integrativa: método de pesquisa para a incorporação de evidências na saúde e na enfermagem. **Texto & Contexto - Enfermagem**, v. 17, n. 4, p. 758–764, dez. 2008. Disponível em: <https://www.redalyc.org/articulo.oa?id=71411240017>. Acesso em: 15 jul. 2022.

MENON, U. *et al.* Precision health research and implementation reviewed through the conNECT framework. **Nursing outlook**, v. 67, n. 4, p. 302–310, jul./ago. 2019. DOI: <https://doi.org/10.1016/j.outlook.2019.05.010>

MOGHADAS, S. M. *et al.* The impact of vaccination on COVID-19 outbreaks in the United States. **medRxiv**, 30 nov. 2020. DOI: <https://doi.org/10.1101/2020.11.27.20240051>

MOHER, D. *et al.* Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement. **PLoS Medicine**, v. 6, n. 7, jul. 2009. DOI: <https://doi.org/10.1371/journal.pmed.1000097>

MONTEZELI, J. H.; HADDAD, M. do C. F. L.; PERES, A. M.; MATSUDA, L. M. Aproximações entre habilidades sociais, gerência do cuidado de enfermagem e o pensamento complexo. **REME: Revista Mineira de Enfermagem**, v. 22, 2018. <http://dx.doi.org/10.5935/1415-2762.20180022>

MORIN, E. **Introdução ao pensamento complexo**. 5. ed. Porto Alegre: Sulina, 2015.

MUNRO C. L. Individual genetic and genomic variation: a new opportunity for personalized nursing interventions. **Journal of Advanced Nursing**, v. 71, n. 1, p. 35–41, 2015. DOI: 101111/jan.12552

OBENSHAIN, M. K. Application of Data Mining Techniques to Healthcare Data. **Hospital Epidemiology**, v. 25, n. 8, p. 690–695, 2004. DOI: 10.1086/502460

OMS. Organização Mundial da Saúde. **Transmission of SARS-CoV-2: implications for infection prevention precautions**. 9 jul. 2020. Disponível em: <https://www.who.int/news-room/commentaries/detail/transmission-of-sars-cov-2-implications-for-infection-prevention-precautions>. Acesso em: 26 jan. 2022.

OPAS. Organização Pan-Americana da Saúde. **Oito Princípios Orientadores da Transformação Digital do Setor da Saúde**. Um apelo à ação pan-americana. Washington: OPAS: 2021. Disponível em: <https://iris.paho.org/handle/10665.2/54669>. Acesso em: 21 fev. 2022.

PADRINI-ANDRADE, L. *et al.* Competências em informática necessárias ao enfermeiro no contexto hospitalar: revisão integrativa. **Journal of Health Informatics**, v. 13, n. 4, p. 133-138, 2021. Disponível em: <http://www.jhi-sbis.saude.ws/ojs-jhi/index.php/jhi-sbis/article/view/893/478>. Acesso em: 26 jun. 2022.

PALAMIM, C.; MARSON, F. COVID-19 – The Availability of ICU Beds in Brazil during the Onset of Pandemic. **Annals of Global Health**, v. 86, n. 1, p. 100–101, 2020. DOI: 10.5334/aogh.3025

PAUDEL, S. *et al.* The Coronavirus Pandemic: What Does the Evidence Show? **Journal of Nepal Health Research Council**, v. 18, n. 1, p. 1–9, 19 abr. 2020. DOI: <https://doi.org/10.33314/jnhrc.v18i1.2596>

PEREIRA, R. H. M. *et al.* Geographic access to COVID-19 healthcare in Brazil using a balanced float catchment area approach. **Social Science & Medicine**, v. 273, 113773, Mar. 2021, 19 jul. 2020. DOI: 10.1016/j.socscimed.2021.113773

PEZZI, M. DA C. S. *et al.* Desenvolvimento de um Protótipo Instrucional para Procedimentos Técnicos em Centro de Material e Esterilização. **Texto & Contexto - Enfermagem**, v. 29, p. 1–11, 2020. DOI: <https://doi.org/10.1590/1980-265X-TCE-2019-0047>

- PIQUEIRA, J. R. C. Complexidade Computacional e Medida da Informação: caminhos de Turing e Shannon. **Estudos Avançados**, v. 30, n. 87, maio-ago. 2016. DOI: <https://doi.org/10.1590/S0103-40142016.30870020>
- PIQUEIRA, J. R. C.; OLIVEIRA, S. M. Engenharia de sistemas complexos. **Estudos Avançados**, v. 31, n. 91, p. 249–255, 1 set. 2017. Disponível em: <https://www.revistas.usp.br/eav/article/view/141916>. Acesso em: 21 jun. 2022.
- POLIT, D.; BECK, C. T. **Fundamentos de Pesquisa em Enfermagem**: Avaliação de evidências para a prática da enfermagem. 9. ed. Porto Alegre: Artmed, 2019.
- PRADIPTA, G. A. *et al.* Machine learning model for umbilical cord classification using combination coiling index and texture feature based on 2-D Doppler ultrasound images. **Health Informatics Journal**, v. 28, n. 1, p. 146045822210842, 29 jan. 2022. DOI: 10.1177/14604582221084211
- PRESSMAN, R.S.; MAXIM, B. R. **Engenharia de software**: uma abordagem profissional. 8. ed. Porto Alegre: Mc Graw Hill; 2016.
- RAJKOMAR, A. *et al.* Ensuring Fairness in Machine Learning to Advance Health Equity. **Annals of internal medicine**, v. 169, n. 12, p. 866, 18 dez. 2018. DOI: 10.7326/M18-1990
- REBÊLO, V. C. N. *et al.* Post Covid-19 Syndrome: case study. **Research, Society and Development**, v. 11, n. 2, p. e43811225969–e43811225969, 31 jan. 2022. DOI: 10.33448/rsd-v11i2.25969
- ROBINSON, P. N. Deep phenotyping for precision medicine. **Human Mutation**, v. 33, n. 5, p. 777–780, 1 maio 2012. DOI: 10.1002/humu.22080
- ROSE, P. M. Patients' characteristics informing practice: improving individualized nursing care in the radiation oncology setting. **Supportive Care in Cancer**, v. 26, n. 10, p. 3609–3618, 1 out. 2018. DOI:10.1007/s00520-018-4210-5
- SANTA CATARINA. Secretaria do Estado da Saúde. **Boletins – Coronavírus**. 2023. Disponível em: <http://www.coronavirus.sc.gov.br/boletins>. Acesso em: 23 mai. 2023.
- SANTA CATARINA. Secretaria do Estado da Saúde. **Vacinômetro – Coronavírus**. 2023a. Disponível em: <https://www.coronavirus.sc.gov.br/vacinometro/>. Acesso em: 23 mai. 2023.
- SANTOS, W. G. Impact of virus genetic variability and host immunity for the success of COVID-19 vaccines. **Biomedicine & pharmacotherapy**, v. 136, p. 111272, 2021. DOI: 10.1016/j.biopha.2021.111272.
- SANTOS, K. M. *et al.* Artificial intelligence, machine learning, computer-aided diagnosis, and radiomics: Advances in imaging towards to precision medicine. **Radiologia Brasileira**, v. 52, n. 6, p. 387–396, 1 nov. 2019. DOI: <https://doi.org/10.1590/0100-3984.2019.0049>

SCHESTATSKY, P. **Medicina do amanhã**: como a genética, o estilo de vida e a tecnologia juntos podem auxiliar na sua qualidade de vida. 3. ed. São Paulo: Editora Gente, 2020.

SCIKIT LEARN. **sklearn.preprocessing.StandardScaler**: scikit-learn 1.3.0. 2023. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>. Acesso em: 28 mar. 2022.

SHIMIZU, H.; NAKAYAMA, K. I. Artificial intelligence in oncology. **Cancer Science**, v. 111, n. 5, p. 1452-1460, 1 maio 2020. DOI: 10.1111/cas.14377

SHUKLA, S.; MAHESHWARI, A.; JOHRI, P. Comparative Analysis of ML Algorithms & Stream Lit Web Application. **2021 3rd International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)**, Greater Noida, India, p. 175-180, 2021. DOI: 10.1109/ICAC3N53548.2021.9725496.

SILVA, V. L. dos S.; FURLAN, M. L. de S.; FABRÍCIO-WEHBE, S. C. C. Identificação do volume residual em equipos de soluções parenterais após administração de medicamentos. **Rev. enferm. UERJ**, v. 19, n. 2, p. 192–197, 2011. Disponível em: <http://www.revenf.bvs.br/pdf/reuerj/v19n2/v19n2a04.pdf>. Acesso em: 24 jan. 2022.

SODER, R. *et al.* Práticas de enfermeiros na gestão do cuidado na atenção básica. **Revista Cubana de Enfermería**, v. 36, n. 1, 18 mar. 2020. Disponível em: <https://revenfermeria.sld.cu/index.php/enf/article/view/2815>. Acesso em: 15 jul. 2022.

SOUZA, D. A Enfermagem ante a covid-19: reflexões para a intervenção praxica. **Avances en Enfermería**, v. 38, n. 1supl, p. 81–90, 18 mar. 2020. DOI: <https://doi.org/10.15446/av.enferm.v38n1supl.89448>

SPANAKIS, M.; PATELAROU, A. E.; PATELAROU, E. Nursing Personnel in the Era of Personalized Healthcare in Clinical Practice. **Journal of Personalized Medicine**, v. 10, n. 3, p. 1–19, 1 set. 2020. DOI: 10.3390/jpm10030056

STREAMLIT. **The fastest way to build and share data apps**. 2023. Disponível em: <https://streamlit.io/>. Acesso em: 4 abr. 2022.

SUBUDHI, S. *et al.* Comparing machine learning algorithms for predicting ICU admission and mortality in COVID-19. **NPJ Digital Medicine**, v. 4, n. 1, p. 87, 1 dez. 2021. DOI: 10.1038/s41746-021-00456-x

TAYLOR, N. *et al.* Validation of the patient measure of safety (PMOS) questionnaire in Australian public hospitals. **Int J Qual Health Care**, v. 32, n. Suppl 1, p. 67-74, 2020. DOI: <https://doi.org/10.1093/intqhc/mzz097>

TING, D. S. W.; CARIN, L.; DZAU, V.; WONG, T. Y. Digital technology and COVID-19. **Nature Medicine**, v. 26, n. 4, p. 459–461, 27 mar. 2020. DOI: <https://doi.org/10.1038/s41591-020-0824-5>

UNIVERSITY OF OXFORD. Oxford Centre for Evidence-Based Medicine. **Oxford Centre for Evidence-Based Medicine: Levels of Evidence** (March 2009). Oxford, 2009. Disponível em: <https://www.cebm.ox.ac.uk/resources/levels-of-evidence/oxford-centre-for-evidence-based-medicine-levels-of-evidence-march-2009>. Acesso em: 24 jan. 2022.

VALERIO NETTO, A.; BERTON, L.; TAKAHATA, A. K. **Ciência de dados e inteligência artificial na área da saúde**. São Paulo: Editora dos editores, 2021.

WERNER, C. R. *et al.* How Population Structure Impacts Genomic Selection Accuracy in Cross-Validation: Implications for Practical Breeding. **Frontiers in Plant Science**, v. 11, p. 592977, 16 dez. 2020. DOI: <https://doi.org/10.3389/fpls.2020.592977>

WEBER, L. A. F.; LIMA, M. A. D. S.; ACOSTA, A. M. Quality of care transition and its association with hospital readmission. **Aquichan**, v. 19, n. 4, e1945, 2019. DOI: <http://dx.doi.org/10.5294/aqui.2019.19.4.5>

WILDER-SMITH, A.; FREEDMAN, D. O. Isolation, quarantine, social distancing and community containment: Pivotal role for old-style public health measures in the novel coronavirus (2019-nCoV) outbreak. **Journal of travel medicine**, v. 27, n. 2, 2020. DOI:10.1093/jtm/taaa020

ZHENG, X. *et al.* The effect of three-stage preventive nursing on older patients with frailty. **Journal of the American Geriatrics Society**, v. 67, n. 10, S664-S665, 2019.

YUAN, C. Precision Nursing: New Era of Cancer Care. **Cancer Nursing**, v. 38, n. 5, p. 333–334, 2015. DOI: 10.1097/NCC.0000000000000290

## APÊNDICE A – PROTOCOLO PARA REVISÃO INTEGRATIVA DA LITERATURA

<b>PROTOCOLO PARA REVISÃO INTEGRATIVA DA LITERATURA</b>
<p><b>I. RECURSOS HUMANOS</b></p> <p>1. Dda. Greici Capellari Fabrizio 2. Profª Dra. Alacoque Lorenzini Erdmann</p>
<p><b>II. PARTICIPAÇÃO DOS PESQUISADORES</b></p> <p>Elaboração protocolo: 1 Coleta de dados: 1 Seleção dos estudos: 1 Checagem dos dados coletados: 1 Avaliação crítica dos estudos: 1, 2 Síntese dos dados: 1 Análise dos dados, resultados e elaboração do artigo: 1, 2 Apreciação final, avaliação e sugestões: 1, 2 Revisão final a partir de sugestões da orientadora: 1 *Os algarismos numéricos foram utilizados para relacionar os pesquisadores participantes em cada etapa.</p>
<p><b>III. VALIDAÇÃO EXTERNA DO PROTOCOLO</b></p> <p>Profª Dra. Alacoque Lorenzini Erdmann</p>
<p><b>IV. TEMA</b></p> <p>Enfermagem de Precisão nas pesquisas de enfermagem</p>
<p><b>V. PERGUNTA</b></p> <p>Quais as produções descritas na literatura científica sobre Enfermagem de Precisão?</p>
<p><b>VI. OBJETIVO</b></p> <p>Analisar a produção científica acerca da Enfermagem de Precisão.</p>
<p><b>VII. DESENHO DO ESTUDO</b></p> <p>Trata-se de uma revisão integrativa da literatura, desenvolvida com base em seis etapas sequenciais e independentes, propostas por Mendes Silveira e Galvão (2008):</p> <ol style="list-style-type: none"> <li>1) Identificação da temática e elaboração da pergunta de pesquisa;</li> <li>2) Definição de critérios de inclusão e exclusão das produções científicas e busca nas bases de dados;</li> <li>3) Definição das informações para compor o banco de dados e a categorização dos artigos</li> <li>4) Avaliação criteriosa dos estudos selecionados</li> <li>5) Análise dos dados</li> <li>6) Síntese da revisão</li> </ol>
<p><b>VIII. CRITÉRIOS DE INCLUSÃO</b></p> <p>Serão incluídos no estudo artigos originais, editoriais e anais de eventos, disponíveis na íntegra, nos idiomas português, inglês e espanhol, sem adotar recorte temporal.</p>
<p><b>IV. CRITÉRIOS DE EXCLUSÃO</b></p> <p>Serão excluídas publicações duplicadas, fora de escopo temático da pesquisa e</p>

revisões integrativas, teses e dissertações.

#### **X. DESCRITORES E PALAVRAS CHAVES UTILIZADOS**

Foram utilizadas palavras-chaves e descritores provenientes do *Medical Subject Headings* (MeSH) e do Descritores em Ciências da Saúde (DeCS), nos idiomas português, inglês e espanhol, com uso do operador booleano *OR*.

##### **Assunto 1:**

"Enfermagem de Precisão"  
 "Enfermagem Individualizada"  
 "Enfermagem personalizada"  
  
 "Enfermería de precisión"  
 "Enfermería individualizada"  
 "Enfermería personalizada"  
  
 "Precision Nursing"  
 "Personalized Nursing"  
 "Individualized nursing"

#### **XI. BASES ELETRÔNICAS DE DADOS**

SCOPUS  
*Cumulative Index to Nursing and Allied Health Literature* (CINAHL)  
*Medical Literature Analysis and Retrieval System Online* (PubMed/MEDLINE)  
 COCHRANE  
*Web of Science*  
 EMBASE  
 Literatura Latino-Americana e do Caribe em Ciências da Saúde (LILACS/BDENF)  
*Scientific Eletronic Library Online* (SciElo)

#### **XII. A ESTRATÉGIA DE BUSCA**

SCOPUS  
 TITLE-ABS-KEY("Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing")  
*Cumulative Index to Nursing and Allied Health Literature* (CINAHL)  
 "Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing"  
*Medical Literature Analysis and Retrieval System Online* (PubMed/MEDLINE)  
 "Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing"  
 COCHRANE  
 "Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing"  
*Web of Science*  
 TS=("Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing")  
 EMBASE  
 "Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing"  
 Literatura Latino-Americana e do Caribe em Ciências da Saúde (LILACS/BDENF)  
 "Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing" OR "Enfermagem de Precisão" OR "Enfermagem Individualizada" OR "Enfermagem personalizada" OR "Enfermería de precisión" OR "Enfermería individualizada" OR "Enfermería personalizada"  
*Scientific Eletronic Library Online* (SciElo)  
 "Precision Nursing" OR "Personalized Nursing" OR "Individualized nursing" OR

"Enfermagem de Precisão" OR "Enfermagem Individualizada" OR "Enfermagem personalizada" OR "Enfermeria de precisión" OR "Enfermería individualizada" OR "Enfermería personalizada"

### XIII. INFORMAÇÕES A SEREM EXTRAÍDAS DAS PRODUÇÕES

Instrumento proposto pelo estudo de Souza, Zeitoun e Barros (2011), adaptado pelos pesquisadores, contendo os seguintes itens:

Identificação do artigo:

- Título
- Link de acesso ao artigo
- Base de dados de publicação
- Autores
- Vinculação do primeiro autor
- Estado/país do primeiro autor
- Periódico
- Ano de publicação
- Descritores

Dados referentes à pesquisa:

- Objetivo
- Método
- Cenário
- População
- Principais achados
- Aplicações da Enfermagem de Precisão

### XIV. CRONOGRAMA

Atividade	Janeiro 2021	Fevereiro 2021	Março 2021	Abril 2021
Elaboração do protocolo	X			
Validação do protocolo	X			
Busca dos estudos	X			
Seleção dos estudos	X			
Organização dos estudos	X			
Avaliação crítica dos estudos		X		
Análise dos dados coletados		X	X	
Discussão e conclusão			X	X

Este protocolo foi adaptação ao modelo elaborado por (Forte; Medeiros; Pires, 2013).

## APÊNDICE B – INSTRUMENTO DE COLETA DE DADOS

1. Número de identificação:
2. Nome do paciente:
3. Data da internação:
4. Data da alta:
5. Data da coleta:
6. Hospital:
<b>7. Questionário sociodemográfico:</b>
8. Qual é a sua idade? (coletar variável contínua)
<p>9. Eu vou listar algumas opções para o/a Sr (a) escolher, me diga qual se identifica em relação ao gênero:</p> <p><input type="checkbox"/> 1- Masculino</p> <p><input type="checkbox"/> 2- Feminino</p> <p><input type="checkbox"/> 3- Outros</p> <p><input type="checkbox"/> 4- Prefiro não informar</p> <p><input type="checkbox"/> 99- Entrevista suspensa</p>
<p>10. Qual é o seu maior grau de instrução?</p> <p><input type="checkbox"/> 1- Sem instrução e menos de 1 ano de estudo</p> <p><input type="checkbox"/> 2- Ensino fundamental incompleto</p> <p><input type="checkbox"/> 3- Ensino fundamental completo</p> <p><input type="checkbox"/> 4- Ensino médio incompleto</p> <p><input type="checkbox"/> 5- Ensino médio completo</p> <p><input type="checkbox"/> 6- Ensino superior incompleto</p> <p><input type="checkbox"/> 7- Ensino superior completo</p> <p><input type="checkbox"/> 99- Entrevista suspensa</p>
<p>11. Você saberia dizer qual é a sua raça?</p> <p><input type="checkbox"/> 1- Branca</p> <p><input type="checkbox"/> 2- Preta</p> <p><input type="checkbox"/> 3- Parda</p> <p><input type="checkbox"/> 4- Indígena</p> <p><input type="checkbox"/> 5- Amarela</p> <p><input type="checkbox"/> 6- Não sei responder</p> <p><input type="checkbox"/> 99- Entrevista suspensa</p>
<b>Biomarcadores clínicos:</b>
12. Quantos dias você ficou internado? (total)
13. Quantos dias você ficou internado em UTI?

14. Você fez uso de ventilação mecânica invasiva? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
15. Você possui alguma das comorbidades a seguir:
16. Doença respiratória crônica? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
17. Hipertensão arterial sistêmica? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
18. Doenças cardiovasculares? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
19. Diabetes Mellitus? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
20. Doenças renais? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
21. Obesidade? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
22. Câncer? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
23. Durante o período de internação, você apresentou algum dos seguintes sintomas:
24. Febre? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa

25. Fadiga? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
26. Falta de ar? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
27. Tosse? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
28. Perda de olfato e paladar? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
29. Dor de cabeça? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
30. Dor no corpo (músculos e articulações)? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
31. Náuseas e vômito? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
32. Diarreia? <input type="checkbox"/> 0- Não <input type="checkbox"/> 1- Sim <input type="checkbox"/> 99- Entrevista suspensa
<b>Fenótipo (hábitos de vida):</b>
33. Você possui histórico de tabagismo? <input type="checkbox"/> 0- Não (nunca fumaram ou fumaram menos de 100 cigarros ao longo da vida) <input type="checkbox"/> 1- Sim (fumaram mais de 100 cigarros ao longo da vida e fumam atualmente) <input type="checkbox"/> 99- Entrevista suspensa
<b>Epigenética (determinantes sociais e contexto):</b>
34. Em qual município você reside?

35. Qual é a sua renda familiar (considerando todos os que residem no domicílio)?

- 1- Até R\$2.090
- 2- R\$2.091 a R\$5.225
- 3- R\$5.226 a R\$10.450
- 4- Mais de R\$10.451
- 5- Sem rendimentos
- 6- Prefiro não responder
- 99- Entrevista suspensa

36. Quantas pessoas residem no seu domicílio?

37. Gostaria de receber os resultados da pesquisa? Solicitar o e-mail do participante

## APÊNDICE C - TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO DE CIÊNCIAS DA SAÚDE  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENFERMAGEM

Em nome da Profa Alacoque Lorenzini Erdmann, coordenadora do projeto “Avaliação do cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros”, convido-o a participar como voluntário deste estudo.

O objetivo geral do estudo é avaliar o cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros. A sua participação consta em responder um formulário eletrônico com perguntas relacionadas à temática da pesquisa.

Os benefícios esperados estão relacionados a melhorias no cuidado de enfermagem, já que serão identificadas dificuldades operacionais nos hospitais durante a pandemia de COVID-19. Além disso, o estudo poderá contribuir para o enfrentamento de “novas ondas” de infecção pelo novo coronavírus.

Os desconfortos decorrentes da pesquisa são mínimos, visto que os procedimentos de coleta de dados não irão gerar conflitos ou exposição social dos participantes.

Contudo, caso você, em algum momento, não apresentar condições para prosseguir, você poderá suspender a entrevista definitivamente ou pelo tempo que você achar necessário, sem qualquer tipo de prejuízo.

Durante todo o período da pesquisa você terá a possibilidade de tirar qualquer dúvida ou pedir demais esclarecimentos. Para isso entre em contato com algum dos pesquisadores ou com o Comitê de Ética em Pesquisa.

As informações desta pesquisa serão confidenciais e poderão ser divulgadas apenas em eventos ou publicações, sem a identificação dos voluntários, a não ser entre os responsáveis do estudo, sendo assegurado o sigilo sobre sua participação.

A pesquisa seguirá as determinações do Conselho Nacional de Saúde, que dispõe sobre os cuidados da pesquisa com seres humanos. Caso necessário, você também poderá entrar em contato com o Comitê de Ética em Pesquisa com Seres Humanos. Você gostaria de anotar os dados para contato?

NESTE MOMENTO INICIA-SE A GRAVAÇÃO.

Ciente e de acordo com o que foi exposto, declaro ter a oportunidade de conversar com o pesquisador responsável, para esclarecer todas as minhas dúvidas e estou suficientemente informado. Fica claro que minha participação é voluntária e que posso retirar este consentimento a qualquer momento sem penalidades. Estou ciente também dos objetivos da pesquisa, dos procedimentos aos quais serei submetido, dos possíveis riscos deles provenientes e da garantia de confidencialidade, bem como de esclarecimentos sempre que desejar. Diante do exposto, expresso minha concordância em participar desta pesquisa.

Concordo em participar da pesquisa?

Sim

Não

## APÊNDICE D – TRATAMENTO DOS DADOS

### EXCEL

Os dados excluídos do Excel foram dos pacientes que apresentavam mais de três variáveis com status “entrevista suspensa” identificados por meio de inspeção visual.

### CTM

Foram excluídas as variáveis: data de alta, data da coleta, questões 1 a 15 CTM, pct quem respondeu? se ã quem era?

### UFSC

Excluídos por não terem respondido 99-Entrevista suspensa: A204, A499, A696, A701, A751, A762, A866, A889= 8 pacientes.

### UNIFESP

Excluídos por não terem respondido 99-Entrevista suspensa: C024, C451, C715, C851, C522, C971, C881, C773= 8 pacientes.

### UFRJ

Excluídos por não terem respondido 99-Entrevista suspensa: D339, D499, D158, D705, D341, D313, D324= 7 pacientes.

### UFRN

Excluídos por não terem respondido 99-Entrevista suspensa: F037= 1 paciente.

### UFAM

Excluídos por não terem respondido 99-Entrevista suspensa: G459, G246, G271, G596, G061= 5 pacientes.

### PMOS

Foram excluídas as variáveis: data de alta, data da coleta, questões 1 a 44 PMOS, comentários, horário de início e término da entrevista.

### UFSC

Excluídos por não terem respondido 99-Entrevista suspensa: A499, A696, A361= 3 pacientes.

### UNIFESP

Excluídos por não terem respondido 99-Entrevista suspensa: C660, C895, C788, C1083, C750, C675, C789= 7 pacientes

UFRJ, UFRN, UFAM=0

### TRANSFORMAÇÃO DAS VARIÁVEIS

Número de identificação = id

Data da internação = d\_internacao

Hospital = hospital  
 Qual é a sua idade? = idade  
 Eu vou listar algumas opções para o/a Sr(a) escolher, me diga qual se identifica em relação ao gênero? = genero  
 Qual é o seu maior grau de instrução? = escolaridade  
 Você saberia dizer qual é a sua raça? = raca  
 Em que município você reside? = municipio  
 Qual é a sua renda familiar (considerando todos os que residem no domicílio)? renda  
 Quantas pessoas residem no seu domicílio? pessoas\_domicilio  
 Quantos dias você ficou internado? (total) dias\_internacao  
 Quantos dias você ficou internado em UTI? dias\_uti  
 Você fez uso de ventilação mecânica invasiva? ventilacao\_mecanica  
 Você possui histórico de tabagismo? tabagismo  
 Você possui alguma das comorbidades a seguir: Doença respiratória crônica?  
 doenca\_respiratoria\_cronica  
 Hipertensão Arterial Sistêmica? has  
 Doenças Cardiovasculares? doencas\_cardiovasculares  
 Diabetes Mellitus? dm  
 Doenças Renais? doencas\_renais  
 Obesidade? obesidade  
 Câncer? cancer  
 Durante o período de internação, você apresentou algum dos seguintes sintomas:  
 febre? febre  
 Fadiga? fadiga  
 Falta de ar? dispneia  
 Tosse? tosse  
 Perda de olfato e paladar? perda\_olfato\_paladar  
 Dor de cabeça? cefaleia  
 Dor no corpo (músculos e articulações)? dor\_corpo  
 Náuseas e vômito? nausea\_vomito  
 Diarreia? diarreia

## **PYTHON**

### TRATAMENTO DOS DADOS APÓS EXCLUSÃO DOS DADOS DUPLICADOS

coluna: hospital  
 valores unicos: ['UFSC' 'UNIFESP' 'UFRJ' 'UFRN' 'UFAM']

coluna: idade  
 valores unicos: [62 51 56 39 65 75 58 54 52 66 48 67 45 77 64 91 34 55 23 61 44 57  
 46 50 63 97 40 26 70 78 53 24 92 47 37 30 36 42 81 59 49 43 22 28 73 89  
 68 74  
 21 38 84 72 76 35 25 69 20 99 80 60 41 32 83 29 86 18 87 31 82 71  
 'Não sabe/Não lembra' 79 33 85 96]

coluna: genero

valores unicos: ['1 - Masculino' '2 - Feminino' '4 - Prefiro não informar']

coluna: escolaridade

valores unicos: ['4 - Ensino médio incompleto' '2 - Ensino fundamental incompleto'  
'5 - Ensino médio completo' '7 - Ensino superior completo'  
'1 - Sem instrução e menos de 1 ano de estudo'  
'3 - Ensino fundamental completo' '6 - Ensino superior incompleto' nan  
'99 - Entrevista suspensa']

coluna: raca

valores unicos: ['1 - Branca' '3 - Parda' '2 - Preta' '4 - Indígena' '5 - Amarela'  
'6 - Não sei responder']

coluna: renda

valores unicos: ['2 - R\$2.091 a R\$5.225' '1 - Até R\$2.090' '3 - R\$5.226 a R\$10.450' '4  
- Mais de R\$10.451' '6 - Prefiro não responder' '5 - Sem rendimentos']

coluna: pessoas\_domicilio

valores unicos: [2 5 4 3 1 6 'Está em clínica de repouso' 'Prefiro não responder' 7 8 9  
nan 10 12]

coluna: dias\_internacao

valores unicos: [5 4 23 7 14 60 37 10 25 'Não sabe/não lembra' 9 30 21 6 13 3 8 16  
27 11 12 105 20 15 55 32 38 24 66 17 45 28 22 34 26 18 47 41 29 65 59 31 70 42 19  
58 33 36 80 51 87 107 56 49 124 170 35 100 72 90 53 50 98 79 48 130]

coluna: dias\_uti

valores unicos: [0 3 20 33 16 7 10 5 9 1 8 26 15 30 22 24 17 23 18 44 4 12 14 6 2 19  
28 13 50 35 21 56 'Não sabe/não lembra' 27 25 80 34 60 45 42 32 70]

coluna: ventilacao\_mecanica

valores unicos: ['0 - Não' '1 - Sim' '99 - Entrevista suspensa']

coluna: tabagismo

valores unicos: ['3 - Ex-fumante' '1 - Não fumante' '2 - Fumante'  
'99 - Entrevista suspensa']

coluna: doenca\_respiratoria\_cronica

valores unicos: ['0 - Não' '1 - Sim' '99 - Entrevista suspensa']

coluna: hipertensa

valores unicos: ['0 - Não' '1 - Sim']

coluna: doencas\_cardiovasculares

valores unicos: ['0 - Não' '1 - Sim' '99 - Entrevista suspensa']

coluna: diabetes

valores unicos: ['1 - Sim' '0 - Não' '99 - Entrevista suspensa']

coluna: doencas\_renais  
valores unicos: ['0 - Não' '1 - Sim' '99 - Entrevista suspensa']

coluna: obesidade  
valores unicos: ['0 - Não' '1 - Sim']

coluna: cancer  
valores unicos: ['0 - Não' '1 - Sim']

coluna: febre  
valores unicos: ['1 - Sim' '0 - Não']

coluna: fadiga  
valores unicos: ['1 - Sim' '0 - Não']

coluna: dispneia  
valores unicos: ['1 - Sim' '0 - Não']

coluna: tosse  
valores unicos: ['1 - Sim' '0 - Não']

coluna: perda\_olfato\_paladar  
valores unicos: ['1 - Sim' '0 - Não' '99 - Entrevista suspensa']

coluna: cefaleia  
valores unicos: ['0 - Não' '1 - Sim']

coluna: dor\_corpo  
valores unicos: ['1 - Sim' '0 - Não' '99 - Entrevista suspensa']

coluna: nausea\_vomito  
valores unicos: ['0 - Não' '1 - Sim' '99 - Entrevista suspensa']

coluna: diarreia  
valores unicos: ['0 - Não' '1 - Sim' '99 - Entrevista suspensa']

## ESTRATÉGIAS UTILIZADAS

'99 - Entrevista suspensa' – declarado como valor faltante

Sim e não declarado como 1 e 0 respectivamente

Registro na variável idade 'Não sabe/não lembra' como valor faltando

Variável raça possui o registro '6 - Não sei responder' foi declarado como valor faltante

# Var pessoas\_domicilio 'Está em clínica de repouso' -> como um registro de 20 pessoas

# Var pessoas\_domicilio 'Prefiro não responder' -> valor faltante  
 # dias\_uti 'Não sabe/não lembra' transformado em valor faltante  
 # dias\_uti dias maior que 0 transformado em 1 de outra forma valor zero.

## RESULTADO

coluna: hospital

valores unicos: ['UFSC' 'UNIFESP' 'UFRJ' 'UFRN' 'UFAM']

coluna: idade

valores unicos: [62. 51. 56. 39. 65. 75. 58. 54. 52. 66. 48. 67. 45. 77. 64. 91. 34. 55.  
 23. 61. 44. 57. 46. 50. 63. 97. 40. 26. 70. 78. 53. 24. 92. 47. 37. 30.  
 36. 42. 81. 59. 49. 43. 22. 28. 73. 89. 68. 74. 21. 38. 84. 72. 76. 35.  
 25. 69. 20. 99. 80. 60. 41. 32. 83. 29. 86. 18. 87. 31. 82. 71. nan 79.  
 33. 85. 96.]

coluna: genero

valores unicos: ['1 - Masculino' '2 - Feminino' '4 - Prefiro não informar']

coluna: escolaridade

valores unicos: ['4 - Ensino médio incompleto' '2 - Ensino fundamental incompleto'  
 '5 - Ensino médio completo' '7 - Ensino superior completo'  
 '1 - Sem instrução e menos de 1 ano de estudo'  
 '3 - Ensino fundamental completo' '6 - Ensino superior incompleto' nan]

coluna: raca

valores unicos: ['1 - Branca' '3 - Parda' '2 - Preta' '4 - Indígena' '5 - Amarela'  
 '6 - Não sei responder']

coluna: renda

valores unicos: ['2 - R\$2.091 a R\$5.225' '1 - Até R\$2.090' '3 - R\$5.226 a R\$10.450'  
 '4 - Mais de R\$10.451' nan '5 - Sem rendimentos']

coluna: pessoas\_domicilio

valores unicos: [2. 5. 4. 3. 1. 6. 20. nan 7. 8. 9. 10. 12.]

coluna: dias\_internacao

valores unicos: [(-0.001, 30.0], (30.0, 60.0], NaN, (90.0, 200.0], (60.0, 90.0]]  
 Categories (4, interval[float64]): [(-0.001, 30.0] < (30.0, 60.0] < (60.0, 90.0] < (90.0,  
 200.0]]

coluna: dias\_uti

valores unicos: [0. 1. nan]

coluna: ventilacao\_mecanica

valores unicos: [0. 1. nan]

coluna: tabagismo  
valores unicos: [3 - Ex-fumante' '1 - Não fumante' '2 - Fumante' nan]

coluna: doenca\_respiratoria\_cronica  
valores unicos: [ 0. 1. nan]

coluna: hipertensa  
valores unicos: [0 1]

coluna: doencas\_cardiovasculares  
valores unicos: [ 0. 1. nan]

coluna: diabetes  
valores unicos: [ 1. 0. nan]

coluna: doencas\_renais  
valores unicos: [ 0. 1. nan]

coluna: obesidade  
valores unicos: [0 1]

coluna: cancer  
valores unicos: [0 1]

coluna: febre  
valores unicos: [1 0]

coluna: fadiga  
valores unicos: [1 0]

coluna: dispneia  
valores unicos: [1 0]

coluna: tosse  
valores unicos: [1 0]

coluna: perda\_olfato\_paladar  
valores unicos: [ 1. 0. nan]

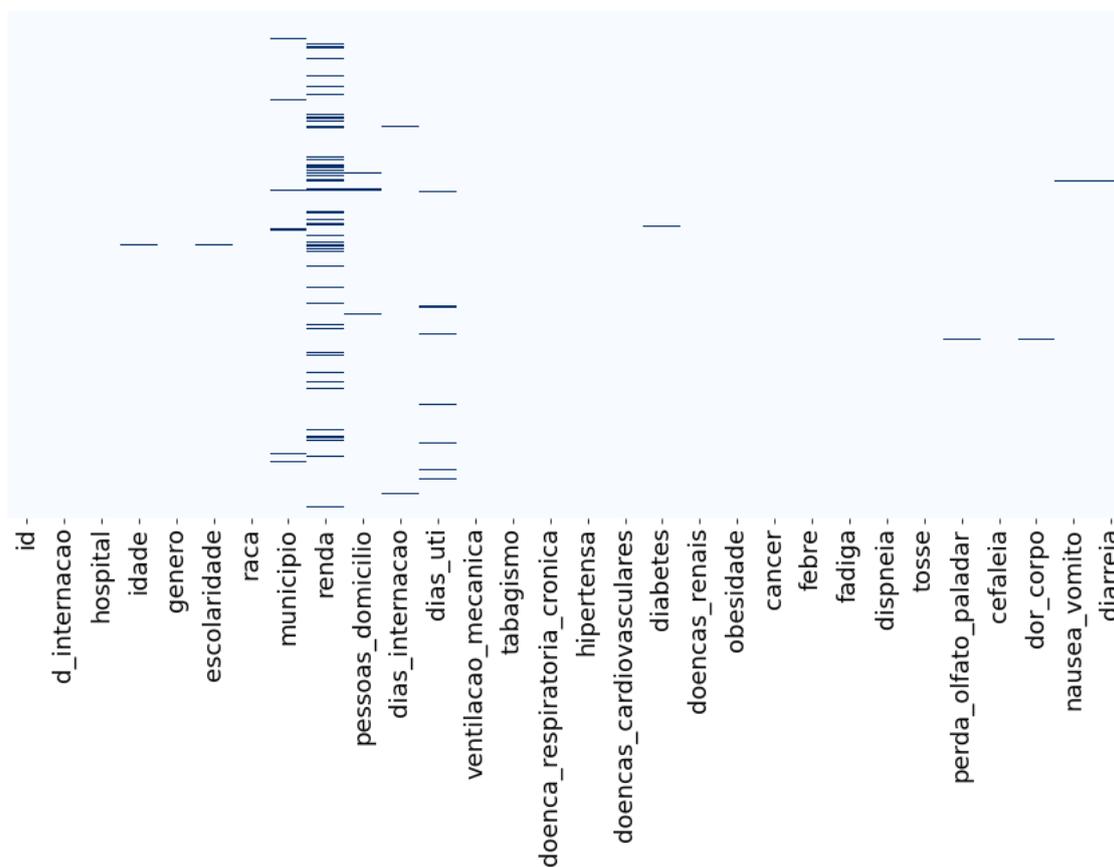
coluna: cefaleia  
valores unicos: [0 1]

coluna: dor\_corpo  
valores unicos: [ 1. 0. nan]

coluna: nausea\_vomito  
valores unicos: [ 0. 1. nan]

coluna: diarreia

valores unicos: [ 0. 1. nan]



### Retiradas colunas sem informação útil para o modelo

As variáveis retiradas do banco de dados foram escolhidas considerando que estas não possuem informações relevantes para a etapa de modelagem, assim como, variáveis que poderiam indicar o desfecho antecipadamente da variável de interesse: ['id', 'municipio', 'd\_internacao', 'dias\_internacao', 'ventilacao\_mecanica']

### ### Retirando registros de pacientes sem desfecho para UTI

Retirando registros/pacientes que possuem informação faltante para o desfecho pretendido na modelagem - dias\_uti. (13 registros retirados).

### Imputando os valores mais frequentes (MODA) aos valores missing

Variável: idade

Quantidade de valores faltantes antes da imputação: 1

Variável: escolaridade

Quantidade de valores faltantes antes da imputação: 2

Variável: renda

Quantidade de valores faltantes antes da imputação: 71

Variável: pessoas\_domicilio

Quantidade de valores faltantes antes da imputação: 4

Variável: tabagismo

Quantidade de valores faltantes antes da imputação: 2

Variável: doenca\_respiratoria\_cronica

Quantidade de valores faltantes antes da imputação: 1

Variável: doencas\_cardiovasculares

Quantidade de valores faltantes antes da imputação: 1

Variável: diabetes

Quantidade de valores faltantes antes da imputação: 1

Variável: doencas\_renais

Quantidade de valores faltantes antes da imputação: 1

Variável: perda\_olfato\_paladar

Quantidade de valores faltantes antes da imputação: 1

Variável: dor\_corpo

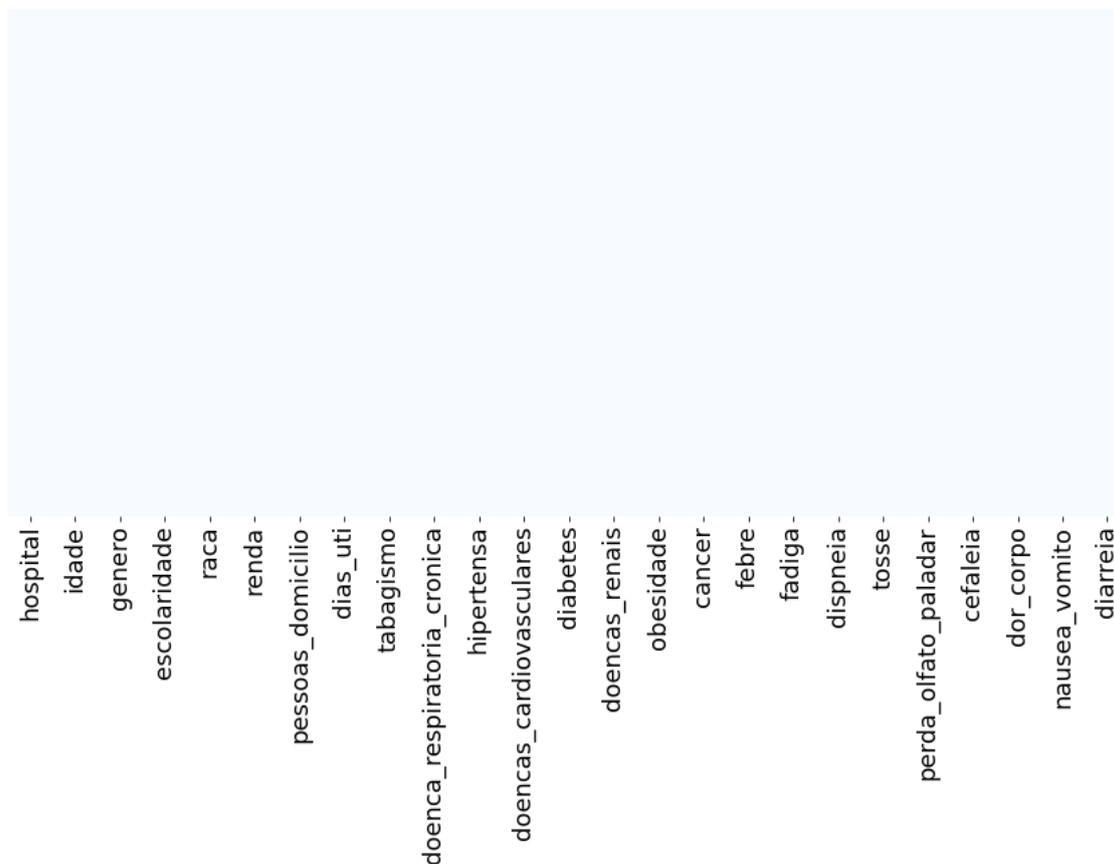
Quantidade de valores faltantes antes da imputação: 1

Variável: nausea\_vomito

Quantidade de valores faltantes antes da imputação: 1

Variável: diarreia

Quantidade de valores faltantes antes da imputação: 1



**Nesta etapa os dados possuem os seguintes valores únicos para cada variável:**

coluna: hospital

valores unicos: ['UFSC' 'UNIFESP' 'UFRJ' 'UFRN' 'UFAM']

coluna: idade

valores unicos: [62. 51. 56. 39. 65. 75. 58. 54. 52. 66. 48. 67. 45. 77. 64. 91. 34. 55. 23. 61. 44. 57. 46. 50. 63. 97. 40. 26. 70. 78. 53. 24. 92. 47. 37. 30. 36. 42. 81. 59. 49. 43. 22. 28. 73. 89. 68. 74. 21. 38. 84. 72. 76. 35. 25. 69. 20. 99. 80. 60. 41. 32. 83. 29. 86. 18. 87. 31. 82. 71. 79. 33. 85. 96.]

coluna: genero

valores unicos: ['1 - Masculino' '2 - Feminino' '4 - Prefiro não informar']

coluna: escolaridade

valores unicos: ['4 - Ensino médio incompleto' '2 - Ensino fundamental incompleto' '5 - Ensino médio completo' '7 - Ensino superior completo' '1 - Sem instrução e menos de 1 ano de estudo' '3 - Ensino fundamental completo' '6 - Ensino superior incompleto']

coluna: raca

valores unicos: ['1 - Branca' '3 - Parda' '2 - Preta' '4 - Indígena' '5 - Amarela'  
'6 - Não sei responder']

coluna: renda

valores unicos: ['2 - R\$2.091 a R\$5.225' '1 - Até R\$2.090' '3 - R\$5.226 a R\$10.450'  
'4 - Mais de R\$10.451' '5 - Sem rendimentos']

coluna: pessoas\_domicilio

valores unicos: [2. 5. 4. 3. 1. 6. 20. 7. 8. 9. 10. 12.]

coluna: dias\_uti

valores unicos: [0. 1.]

coluna: tabagismo

valores unicos: ['3 - Ex-fumante' '1 - Não fumante' '2 - Fumante']

coluna: doenca\_respiratoria\_cronica

valores unicos: [0. 1.]

coluna: hipertensa

valores unicos: [0 1]

coluna: doencas\_cardiovasculares

valores unicos: [0. 1.]

coluna: diabetes

valores unicos: [1. 0.]

coluna: doencas\_renais

valores unicos: [0. 1.]

coluna: obesidade

valores unicos: [0 1]

coluna: cancer

valores unicos: [0 1]

coluna: febre

valores unicos: [1 0]

coluna: fadiga

valores unicos: [1 0]

coluna: dispneia

valores unicos: [1 0]

coluna: tosse

valores unicos: [1 0]

coluna: perda\_olfato\_paladar  
valores unicos: [1. 0.]

coluna: cefaleia  
valores unicos: [0 1]

coluna: dor\_corpo  
valores unicos: [1. 0.]

coluna: nausea\_vomito  
valores unicos: [0. 1.]

coluna: diarreia  
valores unicos: [0. 1.]

## APLICANDO O ONE-HOT ENCODING

### TIPOS DE VARIÁVEIS

Variáveis Numéricas: Idade; Pessoas\_domicilio;

Variáveis Categóricas: demais colunas;

Para que os dados possam ser modelados é necessário transformar os dados categóricos para dados numéricos, onde cada coluna com variável categórica corresponderá a valores binários com zero ou 1.

A exemplo, observa-se abaixo os cinco primeiros registros das variáveis idade e hospital antes da transformação dos dados e após a transformação dos dados onde observa-se que a variável idade sendo numérica se mantém enquanto a variável hospital que é categórica é desmembrada em 5 subcategorias conforme a quantidade de categorias no banco de dados original.

	HOSPITAL	IDADE
	UFSC	62.0
1	UFSC	51.0
2	UFSC	56.0
3	UFSC	39.0
4	UFSC	65.0

	idade	Hospital UFAM	Hospital UFRJ	Hospital UFRN	Hospital UFSC	Hospital UNIFESP
<b>0</b>	62.0	0	0	0	1	0
<b>1</b>	51.0	0	0	0	1	0
<b>2</b>	56.0	0	0	0	1	0
<b>3</b>	39.0	0	0	0	1	0
<b>4</b>	65.0	0	0	0	1	0

Aplicando a técnica de One-Hot Encoding ao banco de dados temos um banco de dados com 48 variáveis (anteriormente 25 variáveis). Abaixo é apresentado o gráfico indicando a inexistência de valores faltantes.

idade -  
 pessoas\_domicilio -  
 dias\_utilizados -  
 doenca\_respiratoria\_cronica -  
 hipertensao -  
 doencas\_cardiovasculares -  
 diabetes -  
 doencas\_renais -  
 obesidade -  
 cancer -  
 febre -  
 fadiga -  
 dispneia -  
 tosse -  
 perda\_olfato\_paladar -  
 cefaleia -  
 dor\_corpo -  
 nausea\_vomito -  
 diarrreia -  
 hospital\_UFAM -  
 hospital\_UFRJ -  
 hospital\_UFRN -  
 hospital\_UFSC -  
 hospital\_UMFESP -  
 genero\_1 - Masculino -  
 genero\_2 - Feminino -  
 genero\_4 - Prefero não informar -  
 escolaridade\_1 - Sem instrução e menos de 1 ano de estudo -  
 escolaridade\_2 - Ensino fundamental incompleto -  
 escolaridade\_3 - Ensino fundamental completo -  
 escolaridade\_4 - Ensino médio incompleto -  
 escolaridade\_5 - Ensino médio completo -  
 escolaridade\_6 - Ensino superior incompleto -  
 escolaridade\_7 - Ensino superior completo -  
 raca\_1 - Branca -  
 raca\_2 - Preta -  
 raca\_3 - Parda -  
 raca\_4 - Indígena -  
 raca\_5 - Amarela -  
 raca\_6 - Não sei responder -  
 renda\_1 - Até R\$2.090 -  
 renda\_2 - R2.091aR5.225 -  
 renda\_3 - R5.226aR10.450 -  
 renda\_4 - Mais de R\$10.451 -  
 renda\_5 - Sem rendimentos -  
 tabagismo\_1 - Não fumante -  
 tabagismo\_2 - Fumante -  
 tabagismo\_3 - Ex-fumante -

Para organização do trabalho é renomeado as variáveis, conforme apresentado abaixo que serão utilizados para o processo de modelagem.



```

idade -
pessoas_domicilio -
dias_uti -
doenca_respiratoria_cronica -
hipertensa -
doencas_cardiovasculares -
diabetes -
doencas_renais -
obesidade -
cancer -
febre -
fadiga -
dispneia -
tosse -
perda_olfato_paladar -
cefaleia -
dor_corpo -
nausea_vomito -
diarreia -
hospital_UFAM -
hospital_UFRJ -
hospital_UFRN -
hospital_UFSC -
hospital_UNIFESP -
Masc -
Fem -
outro -
sem_inst -
fund_inc -
fund_com -
med_inc -
med_comp -
sup_inc -
sup_com -
branca -
preta -
parda -
indigena -
amarela -
sem_resp -
ate_2mil -
2_5_mil -
5_10_mil -
maior_10mil -
sem_rend -
nao_fumante -
fumante -
ex_fumante -

```

## EXPLORAÇÃO DESCRITIVA DOS DADOS

Para a exploração descritiva dos dados realiza-se o agrupamento dos dados em relação à variável alvo ('UTI') que indica se o paciente esteve ou não em unidade de terapia intensiva. Para a realização das descrições é necessário realizar a separação e tratamento das variáveis numéricas e categóricas.

Para as variáveis categóricas, ao realizar o agrupamento, os resultados apresentados levam em consideração somente os dados com resposta 'sim' ou 1 para variável preditora, assim, conforme o exemplo abaixo, das condições de

relacionamento entre variáveis alvo e preditora, no agrupamento realizado somente as linhas em negrito serão consideradas:

dias_uti	doenca_respiratoria_cronica							
	0.0	0.0			254			
	1.0	0.0			187			
	<b>0.0</b>	<b>1.0</b>			<b>55</b>			
	<b>1.0</b>	<b>1.0</b>			<b>51</b>			
	0	0%	1	1%	Total_var	%Total_banco		
<b>UTI</b>								
<b>doenca_respiratoria_cronica</b>	<b>55.0</b>	<b>10.0</b>	<b>51.0</b>	<b>9.0</b>	<b>106.0</b>	<b>19.38</b>		
<b>hipertensa</b>	<b>168.0</b>	<b>31.0</b>	<b>118.0</b>	<b>22.0</b>	<b>286.0</b>	<b>52.29</b>		
<b>doencas_cardiovasculares</b>	<b>85.0</b>	<b>16.0</b>	<b>52.0</b>	<b>10.0</b>	<b>137.0</b>	<b>25.05</b>		
<b>diabetes</b>	<b>108.0</b>	<b>20.0</b>	<b>70.0</b>	<b>13.0</b>	<b>178.0</b>	<b>32.54</b>		
<b>doencas_renais</b>	<b>65.0</b>	<b>12.0</b>	<b>34.0</b>	<b>6.0</b>	<b>99.0</b>	<b>18.10</b>		
<b>obesidade</b>	<b>81.0</b>	<b>15.0</b>	<b>70.0</b>	<b>13.0</b>	<b>151.0</b>	<b>27.61</b>		
<b>cancer</b>	<b>32.0</b>	<b>6.0</b>	<b>19.0</b>	<b>3.0</b>	<b>51.0</b>	<b>9.32</b>		
<b>febre</b>	<b>204.0</b>	<b>37.0</b>	<b>169.0</b>	<b>31.0</b>	<b>373.0</b>	<b>68.19</b>		
<b>fadiga</b>	<b>221.0</b>	<b>40.0</b>	<b>200.0</b>	<b>37.0</b>	<b>421.0</b>	<b>76.97</b>		
<b>dispneia</b>	<b>230.0</b>	<b>42.0</b>	<b>196.0</b>	<b>36.0</b>	<b>426.0</b>	<b>77.88</b>		
<b>tosse</b>	<b>211.0</b>	<b>39.0</b>	<b>168.0</b>	<b>31.0</b>	<b>379.0</b>	<b>69.29</b>		
<b>perda_olfato_paladar</b>	<b>170.0</b>	<b>31.0</b>	<b>119.0</b>	<b>22.0</b>	<b>289.0</b>	<b>52.83</b>		
<b>cefaleia</b>	<b>170.0</b>	<b>31.0</b>	<b>126.0</b>	<b>23.0</b>	<b>296.0</b>	<b>54.11</b>		
<b>dor_corpo</b>	<b>211.0</b>	<b>39.0</b>	<b>165.0</b>	<b>30.0</b>	<b>376.0</b>	<b>68.74</b>		
<b>nausea_vomito</b>	<b>117.0</b>	<b>21.0</b>	<b>73.0</b>	<b>13.0</b>	<b>190.0</b>	<b>34.73</b>		
<b>diarreia</b>	<b>132.0</b>	<b>24.0</b>	<b>91.0</b>	<b>17.0</b>	<b>223.0</b>	<b>40.77</b>		
<b>hospital_UFAM</b>	<b>83.0</b>	<b>15.0</b>	<b>24.0</b>	<b>4.0</b>	<b>107.0</b>	<b>19.56</b>		
<b>hospital_UFRJ</b>	<b>53.0</b>	<b>10.0</b>	<b>41.0</b>	<b>7.0</b>	<b>94.0</b>	<b>17.18</b>		
<b>hospital_UFRN</b>	<b>41.0</b>	<b>7.0</b>	<b>40.0</b>	<b>7.0</b>	<b>81.0</b>	<b>14.81</b>		
<b>hospital_UFSC</b>	<b>47.0</b>	<b>9.0</b>	<b>47.0</b>	<b>9.0</b>	<b>94.0</b>	<b>17.18</b>		
<b>hospital_UNIFESP</b>	<b>85.0</b>	<b>16.0</b>	<b>86.0</b>	<b>16.0</b>	<b>171.0</b>	<b>31.26</b>		
<b>Masc</b>	<b>146.0</b>	<b>27.0</b>	<b>133.0</b>	<b>24.0</b>	<b>279.0</b>	<b>51.01</b>		
<b>Fem</b>	<b>162.0</b>	<b>30.0</b>	<b>102.0</b>	<b>19.0</b>	<b>264.0</b>	<b>48.26</b>		
<b>outro</b>	<b>1.0</b>	<b>0.0</b>	<b>3.0</b>	<b>1.0</b>	<b>4.0</b>	<b>0.73</b>		

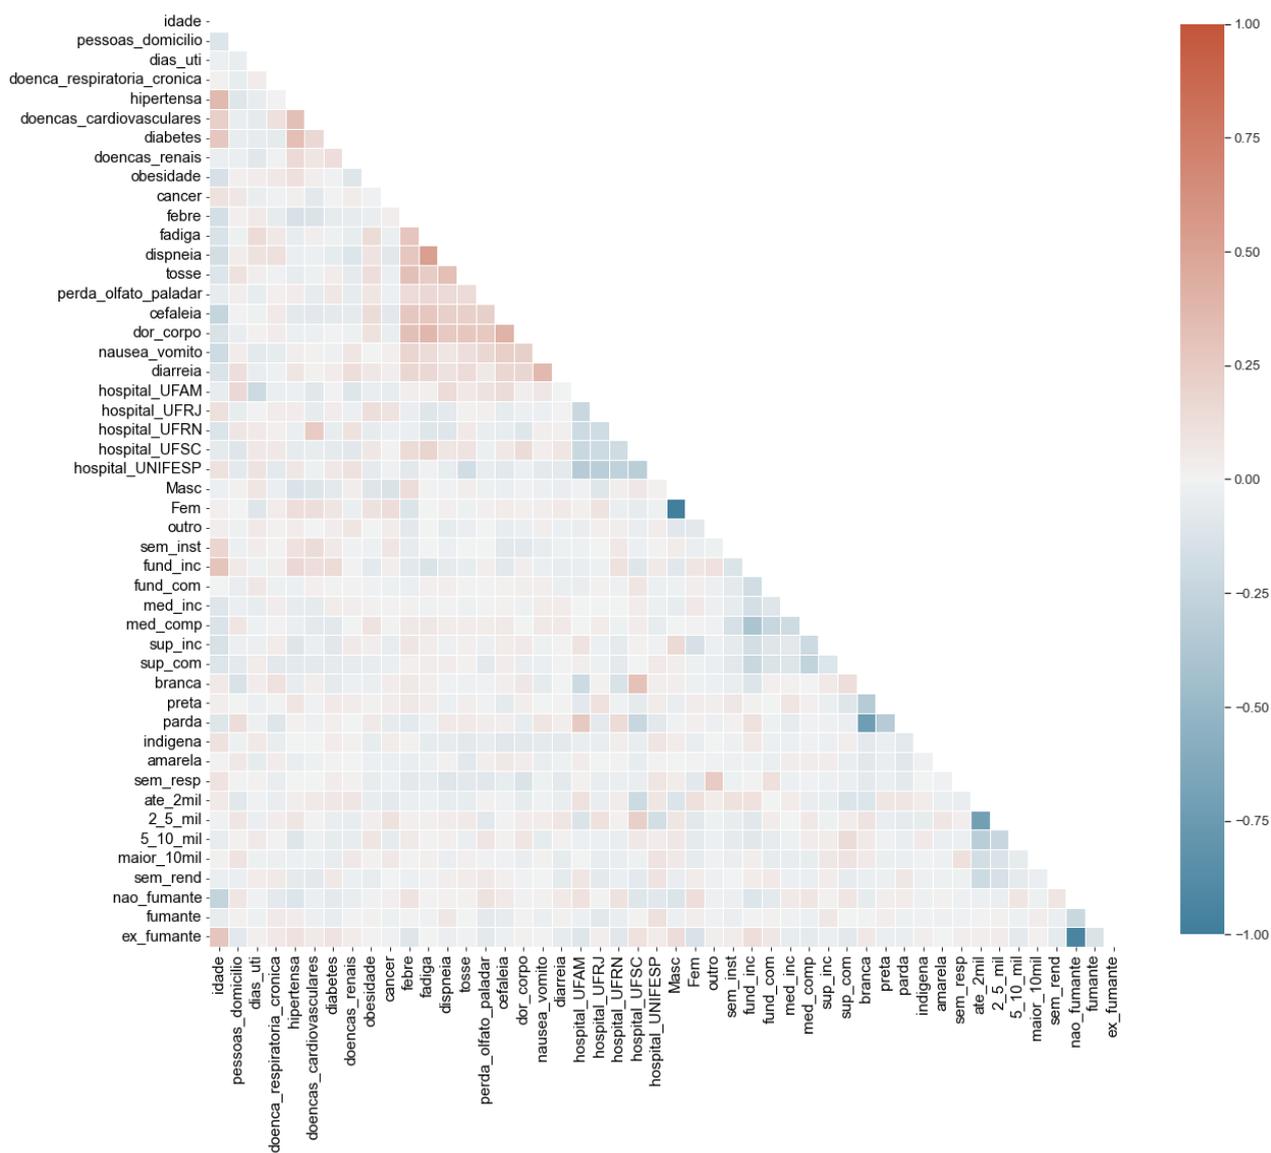
<b>sem_inst</b>	<b>12.0</b>	<b>2.0</b>	<b>13.0</b>	<b>2.0</b>	<b>25.0</b>	<b>4.57</b>
<b>fund_inc</b>	<b>77.0</b>	<b>14.0</b>	<b>55.0</b>	<b>10.0</b>	<b>132.0</b>	<b>24.13</b>
<b>fund_com</b>	<b>25.0</b>	<b>5.0</b>	<b>29.0</b>	<b>5.0</b>	<b>54.0</b>	<b>9.87</b>
<b>med_inc</b>	<b>27.0</b>	<b>5.0</b>	<b>14.0</b>	<b>3.0</b>	<b>41.0</b>	<b>7.50</b>
<b>med_comp</b>	<b>104.0</b>	<b>19.0</b>	<b>75.0</b>	<b>14.0</b>	<b>179.0</b>	<b>32.72</b>
<b>sup_inc</b>	<b>27.0</b>	<b>5.0</b>	<b>17.0</b>	<b>3.0</b>	<b>44.0</b>	<b>8.04</b>
<b>sup_com</b>	<b>37.0</b>	<b>7.0</b>	<b>35.0</b>	<b>6.0</b>	<b>72.0</b>	<b>13.16</b>
<b>branca</b>	<b>125.0</b>	<b>23.0</b>	<b>105.0</b>	<b>19.0</b>	<b>230.0</b>	<b>42.05</b>
<b>preta</b>	<b>43.0</b>	<b>8.0</b>	<b>29.0</b>	<b>5.0</b>	<b>72.0</b>	<b>13.16</b>
<b>parda</b>	<b>133.0</b>	<b>24.0</b>	<b>98.0</b>	<b>18.0</b>	<b>231.0</b>	<b>42.23</b>
<b>indigena</b>	<b>1.0</b>	<b>0.0</b>	<b>3.0</b>	<b>1.0</b>	<b>4.0</b>	<b>0.73</b>
<b>amarela</b>	<b>5.0</b>	<b>1.0</b>	<b>1.0</b>	<b>0.0</b>	<b>6.0</b>	<b>1.10</b>
<b>sem_resp</b>	<b>2.0</b>	<b>0.0</b>	<b>2.0</b>	<b>0.0</b>	<b>4.0</b>	<b>0.73</b>
<b>ate_2mil</b>	<b>153.0</b>	<b>28.0</b>	<b>115.0</b>	<b>21.0</b>	<b>268.0</b>	<b>48.99</b>
<b>2_5_mil</b>	<b>111.0</b>	<b>20.0</b>	<b>78.0</b>	<b>14.0</b>	<b>189.0</b>	<b>34.55</b>
<b>5_10_mil</b>	<b>24.0</b>	<b>4.0</b>	<b>26.0</b>	<b>5.0</b>	<b>50.0</b>	<b>9.14</b>
<b>maior_10mil</b>	<b>10.0</b>	<b>2.0</b>	<b>6.0</b>	<b>1.0</b>	<b>16.0</b>	<b>2.93</b>
<b>sem_rend</b>	<b>11.0</b>	<b>2.0</b>	<b>13.0</b>	<b>2.0</b>	<b>24.0</b>	<b>4.39</b>
<b>nao_fumante</b>	<b>194.0</b>	<b>35.0</b>	<b>147.0</b>	<b>27.0</b>	<b>341.0</b>	<b>62.34</b>
<b>fumante</b>	<b>10.0</b>	<b>2.0</b>	<b>6.0</b>	<b>1.0</b>	<b>16.0</b>	<b>2.93</b>
<b>ex_fumante</b>	<b>105.0</b>	<b>19.0</b>	<b>85.0</b>	<b>16.0</b>	<b>190.0</b>	<b>34.73</b>

Para as variáveis numéricas (idade e pessoas em domicílio), foram também agrupadas pela variável alvo com as informações de média, mediana, quartil 1 (referente a 25% dos dados) e quartil 3 (ref. A 75% dos dados).

<b>dias_uti</b>	<b>0.0</b>	<b>1.0</b>
<b>UTI</b>		
<b>idade_mean</b>	<b>56.06</b>	<b>55.06</b>
<b>pessoas_domicilio_mean</b>		<b>3.27 3.13</b>
<b>idade_median</b>	<b>55.00</b>	<b>56.00</b>
<b>pessoas_domicilio_median</b>		<b>3.00 3.00</b>
<b>idade_25_quant</b>	<b>43.00</b>	<b>45.00</b>

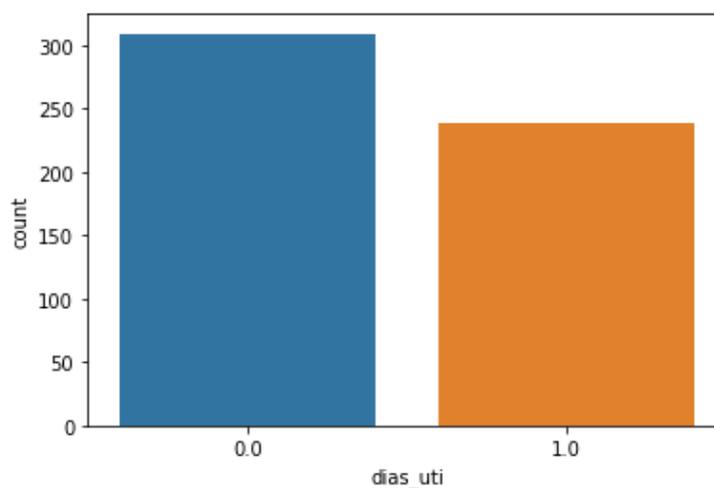
pessoas\_domicilio\_25\_quant 2.00 2.00  
 idade75\_quant 67.00 67.00  
 pessoas\_domicilio75\_quant 4.00 4.00

Por fim foi criado o gráfico chamado correlação para que se possa observar as relações existentes entre as variáveis preditoras.



## MODELAGEM DOS DADOS

Para a modelagem foi selecionada como variável alvo a coluna “dias\_uti” de forma a tentar criar um modelo que pudesse prever a probabilidade de um paciente ir ou não para a UTI a partir das demais variáveis predictoras. Considerando o desfecho, observa-se de acordo com a figura abaixo a existência de maior número de registros de pacientes com desfecho negativo para UTI (309 não foram para UTI e 238 foram para UTI). Este resultado pode influenciar na capacidade preditiva do modelo, porém, inicialmente não foi aplicada nenhuma técnica de compensação nas modelagens iniciais de forma a focar na modelagem.



Os dados foram separados em 75% para treinamento dos modelos e 25% dos dados para testar a capacidade preditiva.

## APÊNDICE E – RELATÓRIO DE VISITA TÉCNICA



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO DE CIÊNCIAS DA SAÚDE  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENFERMAGEM



**Relatório de visita técnica realizada à professora Dra. Louise Pape-Haugaard do Department of Health Science and Technology the Aalborg University.**

**Doutoranda:** Greici Capellari Fabrizzio

**Orientadora:** Profa. Dra. Alacoque Lorenzini Erdmann

**Florianópolis**

**2022**

**Local:** Fredrik Bajers Vej 7, building E2, first floor, room 201b, Department of Health Science and Technology, Aalborg University, Aalborg, Denmark

**Professora:** Dra. Louise Pape-Haugaard - PhD, Master of Science in Medical Informatics, Vice-head for teaching, Head of Studies for educations under HT and SsPh, Associate professor Department of Health Science and Technology, The Faculty of Medicine, Medical Informatics and Image Analysis, Danish Centre for Health Informatics, Institute for Advanced Study in PBL

**Data da visita:** 29 de junho de 2022

A escolha do local da visita técnica ocorreu em virtude da expertise da professora Dra. Louise Pape-Haugaard no desenvolvimento de pesquisas envolvendo modelos preditivos de úlcera em pé diabético para auxiliar na assistência de enfermeiros e publicações na área de medicina personalizada, associada a COVID-19. Ou seja, as temáticas de estudo convergem com o que me propus a desenvolver na tese de doutorado intitulada: “Enfermagem de Precisão e Inteligência Artificial: variáveis preditoras e modelos de decisão da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva”.

O objetivo da visita técnica foi discutir os resultados do estudo retrospectivo, multicêntrico, realizado em cinco hospitais universitários brasileiros para predição da internação de pacientes infectados pela COVID-19 em Unidade de Terapia Intensiva, o que mais tarde subsidiou a interface entre os achados da pesquisa e a literatura científica.

A visita técnica também foi importante para iniciar uma relação com o Department of Health Science and Technology da Aalborg University e estabelecer possibilidade de colaborações internacionais futuras. Após meu retorno para o Brasil, continuamos em contato com a professora Dra. Clara Blender, também do Department of Health Science and Technology da Aalborg University, o que resultou em uma cooperação interinstitucional entre a Universidade Federal de Santa Catarina e a Aalborg University.

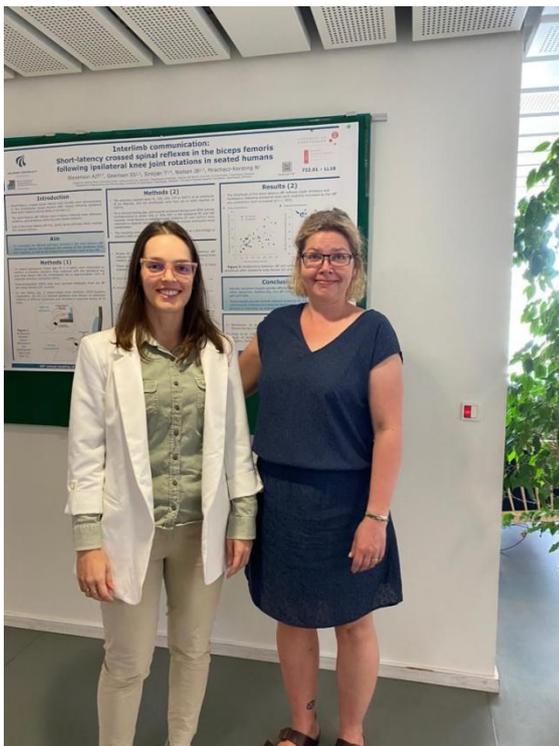
Após reuniões online com a professora Dra. Clara e o Dr. Ole Hejlesen, chefe do Department of Health Science and Technology, Dra. Clara aceitou ser co-

supervisora do meu estágio pós-doutoral. A cooperação resultou na submissão do projeto de pesquisa intitulado “Tecnologias em saúde voltadas para a segurança do paciente: Plataforma de transição do cuidado e modelo de inteligência artificial” na Chamada CNPq/MCTI Nº 10/2023 – UNIVERSAL, a qual está vinculado o meu plano de trabalho do estágio pós-doutoral e a previsão de visita dos pesquisadores Dinamarqueses a Universidade Federal de Santa Catarina. A proposta submetida ao edital considera ainda a participação da Universidade Estadual do Maranhão (UEMA), Universidade Estadual do Amazonas (UEA), Universidade Federal do Ceará (UFC) e da Universidade Regional do Noroeste do Estado do Rio Grande do Sul (Unijuí), também prevê a participação de professores e estudantes das referidas universidades.

A cooperação interinstitucional entre a Universidade Federal de Santa Catarina e a Aalborg University também resultou na submissão da proposta intitulada “Segurança do paciente e Inteligência Artificial: modelos preditivos de indicadores de segurança do paciente” a chamada CNPq n.º 14/2023 - Apoio a projetos internacionais de pesquisa científica, tecnológica e de inovação, em que pleiteamos uma bolsa de pós-doutorado no exterior, a ser realizado no Department of Health Science and Technology da Aalborg University.

Para além disso, foi possível aprofundar o entendimento sobre a estrutura do sistema de saúde dinamarquês e como ocorre a inserção das tecnologias em saúde neste cenário. Foi bastante enriquecedora a experiência de vivenciar e aprender sobre a cultura dinamarquesa.

Foto 1 - Professora Dra. Louise Pape-Haugaard



Fonte: Acervo da autora (2022)

## ANEXO A - APROVAÇÃO DO COMITÊ DE ÉTICA EM PESQUISA

UNIVERSIDADE FEDERAL DE  
SANTA CATARINA - UFSC



### PARECER CONSUBSTANCIADO DO CEP

#### DADOS DO PROJETO DE PESQUISA

**Título da Pesquisa:** Avaliação do cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros

**Pesquisador:** Alacoque Lorenzini Erdmann

**Área Temática:**

**Versão:** 1

**CAAE:** 38912820.3.1001.0121

**Instituição Proponente:** Universidade Federal de Santa Catarina

**Patrocinador Principal:** MINISTERIO DA CIENCIA, TECNOLOGIA E INOVACAO

#### DADOS DO PARECER

**Número do Parecer:** 4.347.463

#### Apresentação do Projeto:

As informações que seguem e as elencadas nos campos "Objetivo da pesquisa" e "Avaliação dos riscos e benefícios" foram retiradas do arquivo PB\_INFORMAÇÕES\_BÁSICAS\_DO\_PROJETO\_...pdf, de 05/10/2020, preenchido pelos pesquisadores.

Segundo os pesquisadores:

Resumo: "No Brasil, os hospitais universitários são centros de referência de média e alta complexidade para o Sistema Único de Saúde (SUS) no atendimento a pacientes com COVID-19. Nesses cenários, destaca-se a atuação da enfermagem, pois é a categoria responsável pela maioria dos cuidados recebidos pelos pacientes durante a hospitalização, podendo influenciar diretamente na qualidade assistencial, segurança do paciente/profissional e busca pela excelência dos resultados institucionais. Assim, este estudo tem como objetivo geral avaliar o cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros, sob a perspectiva dos profissionais e pacientes. Trata-se de uma proposta multicêntrica nacional, que reúne 10 instituições de ensino federais, sendo duas de cada região do Brasil: (1) Sul: Universidade Federal de Santa Catarina (proponente) e Universidade Federal de Santa Maria; (2) Sudeste: Universidade Federal de São Paulo e Universidade Federal do Rio de Janeiro; (3) Nordeste: Universidade Federal do Rio Grande do Norte e Universidade Federal da Bahia; (4) Norte: Universidade Federal do Pará e

**Endereço:** Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401  
**Bairro:** Trindade **CEP:** 88.040-400  
**UF:** SC **Município:** FLORIANOPOLIS  
**Telefone:** (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

UNIVERSIDADE FEDERAL DE  
SANTA CATARINA - UFSC



Continuação do Parecer: 4.347.463

Universidade Federal do Amazonas; e, (5) Centro-oeste: Universidade Federal do Mato Grosso e Universidade Federal de Mato Grosso do Sul. A metodologia será desenvolvida em três etapas, com distintas estratégias de pesquisa quantitativas e qualitativas, considerando os focos avaliados: (1) Gestão hospitalar, com análise dos planos de contingência para enfrentamento da COVID-19 e entrevistas com gestores hospitalares; (2) Liderança, gestão do cuidado e ambiente de prática profissional, com foco na equipe de enfermagem a partir da aplicação de instrumentos para caracterização pessoal e condições laborais, Avaliação do Produto do Cuidar em Enfermagem (APROCENF) e Practice Environment Scale (PES), além de entrevistas qualitativas; (3) Continuidade do cuidado e experiência do paciente, em que serão aplicados instrumentos aos pacientes recuperados da COVID-19 após a alta hospitalar: Patient Measure of Safety (PMOS), Readiness for Hospital Discharge Scale - Adult Form (RHDS) e Care Transitions Measure - CTM-15. Também serão entrevistados os enfermeiros para descrever as estratégias de enfermeiros para a continuidade dos cuidados de pacientes recuperados da COVID-19 após a alta hospitalar. Em cada etapa, serão utilizadas técnicas específicas de coleta e análise de dados quantitativas e qualitativas, conforme o foco estudado. A partir da pesquisa, pretende-se contribuir com a produção de novos conhecimentos para melhoria do cuidado em saúde/enfermagem no SUS no combate a COVID-19. Além disso, busca-se ampliar a massa crítica em termos de profissionais da saúde, estudantes e pesquisadores acerca da qualidade do cuidado para lidar com pandemias e de possíveis estratégias para o desenvolvimento de padrões/boas práticas.”

**Hipótese:**

O cuidado de enfermagem a pacientes com COVID-19 é avaliado positivamente por gestores, profissionais de saúde e pacientes em hospitais universitários brasileiros.

**Metodologia:** “Trata-se de uma proposta multicêntrica, que será desenvolvida por meio um estudo transversal, descritivo e analítico, com articulação entre abordagem quantitativas e qualitativas de pesquisa. Os cenários do estudo serão os 10 Hospitais Universitários vinculados às Universidades Federais que integram o estudo, sendo duas de cada região do Brasil: (1) Sul: Federal de Santa Catarina (proponente) e Federal de Santa Maria; (2) Sudeste: Federal de São Paulo e Federal do Rio de Janeiro; (3) Nordeste: Federal do Rio Grande do Norte e Federal da Bahia; (4) Norte: Federal do Pará e Federal do Amazonas; e, (5) Centro-oeste: Federal do Mato Grosso e

**Endereço:** Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401  
**Bairro:** Trindade **CEP:** 88.040-400  
**UF:** SC **Município:** FLORIANOPOLIS  
**Telefone:** (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

UNIVERSIDADE FEDERAL DE  
SANTA CATARINA - UFSC



Continuação do Parecer: 4.347.463

Federal de Mato Grosso do Sul. A pesquisa será desenvolvida em três etapas, considerando cada um dos focos avaliados no trabalho: 1) Gestão hospitalar; 2) Liderança, gestão do cuidado e ambiente de prática profissional e 3) Continuidade do cuidado e experiência do paciente. ETAPA 1 – GESTÃO HOSPITALAR Consistirá na análise dos planos de contingência para enfrentamento da COVID-19, relatórios institucionais e entrevistas com gestores hospitalares ETAPA 2 – LIDERANÇA, GESTÃO DO CUIDADO E AMBIENTE DE PRÁTICA PROFISSIONAL DE ENFERMAGEM Abordagem quantitativa: Serão aplicados três instrumentos: 1) Caracterização pessoal e condições laborais; 2) Avaliação do produto do cuidar em enfermagem (APROCENF) e 3) Practice Environment Scale (PES). Abordagem qualitativa: Os participantes serão abordados visando explorar suas experiências sobre gestão do cuidado, liderança e ambiente de prática profissional a partir de um roteiro semiestruturado. Para a coleta dos dados qualitativos, os participantes serão convidados a fazer parte da pesquisa por e-mail, fornecido pela instituição, sendo nesse momento, apresentados aos objetivos da pesquisa, abordagem metodológica e ética. Etapa 3 – CONTINUIDADE DO CUIDADO E EXPERIÊNCIA DO PACIENTE Abordagem Quantitativa: A população e amostra será composta por

pacientes que tiveram alta da unidade de internação hospitalar destinada a pacientes com COVID-19. A primeira parte do questionário para coleta de dados conterá variáveis relacionadas à caracterização dos participantes, como: Iniciais do Nome; Data de nascimento; Sexo; Cor/raça;

Escolaridade; Tempo de internação; Hospital; Entrevistador - data/hora. Na sequência, serão utilizados os seguintes instrumentos: (1) Patient Measure of Safety (PMOS); (2) Readiness for Hospital Discharge Scale-Adult Form (RHDS) e (3) Care Transitions Measure - CTM-15. Abordagem Qualitativa: Os participantes desta etapa serão pacientes recuperados da COVID-19 e enfermeiros dos hospitais em que o estudo será desenvolvido. A coleta de dados com os pacientes será realizada por meio de entrevista com roteiro semiestruturado, por telefone, contendo questões essenciais que instiguem a abrangência das informações esperadas, planejadas com base na Técnica de Incidente Crítico. Também serão entrevistados os enfermeiros para descrever as estratégias de enfermeiros para a continuidade dos cuidados de pacientes recuperados da COVID-19 após a alta hospitalar. SESSÃO INTEGRADORA FINAL DE TRANSLAÇÃO DO CONHECIMENTO Serão aplicadas estratégias de Integrated Knowledge Translation, com abordagem colaborativa para pesquisar, o que exige integração dos pesquisadores com usuários do conhecimento, tais como tomadores de decisão, profissionais de saúde, pacientes e formuladores de políticas para garantir aplicabilidade na prática, do conhecimento que será produzido (LORENZINI et al., 2020). Ainda, há possibilidade da elaboração de infográficos, ou outras estratégias de mídia que se mostrarem adequadas para maior alcance dos resultados no público-alvo. OBSERVAÇÃO: A descrição

**Endereço:** Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401  
**Bairro:** Trindade **CEP:** 88.040-400  
**UF:** SC **Município:** FLORIANOPOLIS  
**Telefone:** (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

UNIVERSIDADE FEDERAL DE  
SANTA CATARINA - UFSC



Continuação do Parecer: 4.347.463

detalhada dos instrumentos de coleta de dados e da operacionalização da proposta está apresentada no arquivo em anexo com a versão completa do projeto/brochura do pesquisador”.

**Critérios de inclusão:** Etapa 1: Para a etapa documental, serão incluídos os planos de contingência de enfrentamento à COVID-19 dos hospitais universitários brasileiros. Em relação à parte empírica, os participantes do estudo serão gestores/trabalhadores que participaram da construção/implementação e avaliação dos planos de contingência.

Etapa 2: profissional de enfermagem e ter experiência na atuação na assistência direta aos pacientes em setores de internação durante a pandemia de COVID-19 por, no mínimo, três meses.

Etapa 3: idade > 18 anos; ter fluência no idioma português do Brasil; período mínimo de 72 horas de internação no hospital antes da administração do questionário, por se considerar um período razoável para o paciente conhecer a instituição e responder aos itens do questionário. Já em relação aos enfermeiros, os critérios de inclusão serão: contrato emergencial, celetista ou concursado há pelo menos 3 meses, com experiência no cuidado a pacientes com COVID-19 nos hospitais universitários.

**Critérios de exclusão:** Etapa 1: Para a etapa documental, serão excluídos os Planos de Contingência de enfrentamento à COVID-19 dos hospitais universitários brasileiros que não estejam disponíveis por meio virtual. Em relação à parte empírica, serão excluídos os gestores e trabalhadores que estão afastados ou aqueles que não participaram desse processo, bem como, aqueles que não aceitarem participar do estudo. Etapa 2: profissionais em afastamento laboral no período de coleta de dados.

Etapa 3: pacientes sem capacidade para consentir em participar da pesquisa (por exemplo, devido a alterações neurológicas, psiquiátricas, doença avançada ou em uso de sedação). Pacientes que, apesar de poderem consentir em participar da pesquisa, estão muito debilitados ou angustiados (por exemplo, por dificuldade respiratória, dor ou pós-operatório imediato). Já em relação aos enfermeiros, os critérios de exclusão serão: licença médica e/ou afastamentos de outra natureza durante o período da coleta de dados.

#### **Objetivo da Pesquisa:**

Objetivo Primário:

Avaliar o cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários brasileiros.

**Endereço:** Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401  
**Bairro:** Trindade **CEP:** 88.040-400  
**UF:** SC **Município:** FLORIANOPOLIS  
**Telefone:** (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

UNIVERSIDADE FEDERAL DE  
SANTA CATARINA - UFSC



Continuação do Parecer: 4.347.463

**Objetivo Secundário:**

- Caracterizar os Hospitais Universitários brasileiros no atendimento de pacientes com COVID-19; - Avaliar os planos de contingência para enfrentamento da COVID-19 nos hospitais universitários brasileiros; - Analisar o processo de elaboração/implementação/avaliação dos planos de contingência para enfrentamento da COVID-19 nos hospitais universitários brasileiros;- Caracterizar o perfil e as condições laborais dos profissionais de enfermagem no atendimento a pacientes com COVID-19;- Avaliar a experiência de enfermeiros na gestão do cuidado e liderança à pacientes com COVID em hospitais universitários; - Avaliar o ambiente de prática profissional da equipe de enfermagem; - Desvelar a experiência do paciente com o cuidado de enfermagem na internação hospitalar; - Analisar fatores relacionados à segurança do paciente sob sua perspectiva; - Descrever as estratégias de enfermeiros para a continuidade dos cuidados de pacientes recuperados da COVID-19 após a alta hospitalar; e, - Desenvolver estratégias para translação/tradução do conhecimento e das evidências produzidas aos participantes do estudo.

**Avaliação dos Riscos e Benefícios:**

**Riscos e Benefícios:**

**Riscos:** Informações do formulário base da PB “Não são previstos riscos de natureza física aos participantes do estudo. Porém, há a possibilidade de mobilização emocional relacionada à reflexão sobre prática profissional e/ou do enfrentamento da doença. Os pesquisadores, compreendendo esse potencial risco, irão interromper a coleta de dados, estarão dispostos a ouvir os participantes e retornar a coleta de dados em outro momento, se o participante assim desejar”.

**Benefícios:** “Com relação aos benefícios do estudo, esta pesquisa poderá contribuir com o desenvolvimento de novos conhecimentos para melhoria do cuidado em saúde e enfermagem no enfrentamento da COVID-19. Além disso, o mapeamento da prática de cuidado de enfermagem a pacientes com COVID-19 em hospitais universitários, poderá dar visibilidade aos desafios e às boas práticas de cuidado que têm sido desenvolvidas. Pretende-se também fornecer subsídios para gestores e profissionais a partir do diagnóstico situacional do cuidado de enfermagem nos hospitais universitários brasileiros.”

**Comentários e Considerações sobre a Pesquisa:**

Informações retiradas primariamente do formulário com informações básicas sobre a pesquisa gerado pela Plataforma Brasil e/ou do projeto de pesquisa e demais documentos postados, conforme lista de documentos e datas no final deste parecer.

**Endereço:** Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401  
**Bairro:** Trindade **CEP:** 88.040-400  
**UF:** SC **Município:** FLORIANOPOLIS  
**Telefone:** (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

UNIVERSIDADE FEDERAL DE  
SANTA CATARINA - UFSC



Continuação do Parecer: 4.347.463

Trata-se de um macroprojeto, multicêntrico nacional, transversal, descritivo e analítico, com articulação entre abordagem quantitativas e qualitativas de pesquisa.

Financiamento do MCTIC/CNPq/FNDCT/MS/SCTIE/Decit N° 07/2020, no valor de R\$176.030,00.

País de origem: Brasil.

Número de participantes no Brasil: 3040. A amostragem será composta por 2000 enfermeiro(a)s. 1000 pacientes e 40 gestores hospitalares. Não consta o número de participantes por centro.

Previsão de início do estudo: 01/12/2020.

Previsão de término do estudo: 31/08/2022

**Considerações sobre os Termos de apresentação obrigatória:**

Folha de rosto assinada pelo pesquisador responsável e pela chefe do Departamento de Enfermagem, professora Katia Cilene Godinho Bertencello.

Constam autorizações institucionais, assinadas pelos representantes das seguintes instituições: HU/UFSC/EBSERH; HU/UNIFESP; HUSM/UFSP/EBSERH; HUOL/UFRN/EBSERH; HU/UFRJ; Complexo Hospitalar/UFPA/EBSERH; HUJM/UFMT/EBSERH; HUMAP/UFMS/EBSERH; HUGV/UFAM/EBSERH.

Constam os instrumentos para coleta de dados.

TCLE aos gestores e profissionais e TCLE aos pacientes atendem as exigências da resolução 466/12.

**Recomendações:**

Recomendamos que em próxima submissão as informações de financiamento devem constar da folha de rosto considerando esta informação da CONEP: "No caso específico de agências de fomento nacionais (como, por exemplo, CNPq, FINEP, FAPs, etc.) e internacionais (por exemplo, US-NIH) e, por se entender a dificuldade de coleta da assinatura, aceita-se que os campos nome,

**Endereço:** Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401  
**Bairro:** Trindade **CEP:** 88.040-400  
**UF:** SC **Município:** FLORIANOPOLIS  
**Telefone:** (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

UNIVERSIDADE FEDERAL DE  
SANTA CATARINA - UFSC



Continuação do Parecer: 4.347.463

cargo/função, CPF, assinatura e data estejam em branco na parte reservada ao patrocinador, desde que o órgão financiador esteja expressamente identificado na Folha de Rosto e que seja apresentado documento comprobatório do financiamento. Cabe esclarecer que o preenchimento do nome do patrocinador (campo 18 da Folha de Rosto) é automático, estando vinculado ao campo "FINANCIAMENTO" da Plataforma Brasil. Somente o nome do responsável pelo "Financiamento primário" será listado na Folha de Rosto como patrocinador."

**Conclusões ou Pendências e Lista de Inadequações:**

Aprovado.

**Considerações Finais a critério do CEP:**

Lembramos aos pesquisadores da necessidade de encaminhar ao CEP notificações com relatórios e parciais e final.

**Este parecer foi elaborado baseado nos documentos abaixo relacionados:**

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1621138.pdf	05/10/2020 22:32:15		Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_GESTORES_PROFISSIONAIS.pdf	05/10/2020 22:31:12	Alacoque Lorenzini Erdmann	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE_PROFISSIONAIS_PACIENTES_online.pdf	05/10/2020 22:31:05	Alacoque Lorenzini Erdmann	Aceito
Projeto Detalhado / Brochura Investigador	Projeto_final_CEP.pdf	05/10/2020 22:30:57	Alacoque Lorenzini Erdmann	Aceito
Folha de Rosto	FolhaDeRosto_OK.pdf	05/10/2020 10:54:04	José Luís Guedes dos Santos	Aceito
Declaração de Instituição e Infraestrutura	UNIFESP.pdf	05/10/2020 10:52:43	José Luís Guedes dos Santos	Aceito
Declaração de Instituição e Infraestrutura	UFSM.pdf	05/10/2020 10:52:36	José Luís Guedes dos Santos	Aceito
Declaração de	UFSC.pdf	05/10/2020	José Luís Guedes	Aceito

**Endereço:** Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401  
**Bairro:** Trindade **CEP:** 88.040-400  
**UF:** SC **Município:** FLORIANOPOLIS  
**Telefone:** (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

UNIVERSIDADE FEDERAL DE  
SANTA CATARINA - UFSC



Continuação do Parecer: 4.347.463

Instituição e Infraestrutura	UFSC.pdf	10:52:26	dos Santos	Aceito
Declaração de Instituição e Infraestrutura	UFRN.PDF	05/10/2020 10:52:19	José Luís Guedes dos Santos	Aceito
Declaração de Instituição e Infraestrutura	UFRJ.pdf	05/10/2020 10:52:09	José Luís Guedes dos Santos	Aceito
Declaração de Instituição e Infraestrutura	UFPA.pdf	05/10/2020 10:51:57	José Luís Guedes dos Santos	Aceito
Declaração de Instituição e Infraestrutura	UFMT.pdf	05/10/2020 10:51:44	José Luís Guedes dos Santos	Aceito
Declaração de Instituição e Infraestrutura	UFMS.pdf	05/10/2020 10:51:35	José Luís Guedes dos Santos	Aceito
Declaração de Instituição e Infraestrutura	UFBA.pdf	05/10/2020 10:51:28	José Luís Guedes dos Santos	Aceito
Declaração de Instituição e Infraestrutura	UFAM.pdf	05/10/2020 10:51:22	José Luís Guedes dos Santos	Aceito

**Situação do Parecer:**

Aprovado

**Necessita Apreciação da CONEP:**

Não

FLORIANOPOLIS, 19 de Outubro de 2020

Assinado por:  
**Nelson Canzian da Silva**  
(Coordenador(a))

**Endereço:** Universidade Federal de Santa Catarina, Prédio Reitoria II, R: Desembargador Vitor Lima, nº 222, sala 401  
**Bairro:** Trindade **CEP:** 88.040-400  
**UF:** SC **Município:** FLORIANOPOLIS  
**Telefone:** (48)3721-6094 **E-mail:** cep.propesq@contato.ufsc.br

## ANEXO B – TRABALHO DERIVADO DO ARTIGO 2 APRESENTADO E PUBLICADO NOS ANAIS DO XVIII CONGRESSO BRASILEIRO DE INFORMÁTICA EM SAÚDE EM 2021

Anais do XVIII Congresso Brasileiro de Informática em Saúde e 10º Congresso Brasileiro de Telemedicina e Telessaúde

22 a 26 de novembro de 2021 - Evento Virtual - Brasil

### Aplicação de algoritmos de predição da internação em Unidade de Terapia Intensiva em pacientes internados com COVID-19

Greici C. Fabrizzio<sup>1</sup>, Lincoln M. de Oliveira<sup>2</sup>, Alacoque L. Erdmann<sup>1</sup>

<sup>1</sup>Universidade Federal de Santa Catarina, Florianópolis, SC

<sup>2</sup>Universidade Federal do Ceará, Fortaleza, CE

greiciapellari@gmail.com, lincolnsobral@yahoo.com.br, alacoque.erdmann@ufsc.br

**Resumo.** O presente estudo objetivou, aplicar e comparar algoritmos de aprendizado de máquina para predição da admissão em Unidade de Terapia Intensiva por pacientes contaminados pela COVID-19, internados em complexo hospitalar. Estudo retrospectivo das notificações do município de Florianópolis, no período de março de 2020 a abril de 2021. Amostra composta por 180 pacientes, 90 deles passaram por Unidade de Terapia Intensiva e foram selecionados randomicamente mais 90 pacientes para equiparar os dados. Utilizou-se do software Orange Data Mining para exploração e análise dos dados. A performance dos algoritmos (rede neural, adaboost, regressão logística, floresta aleatória, kNN, Naive Bayes, SVM e árvore de decisão) foram validadas por meio da técnica de validação cruzada dos dados e as métricas de performance utilizadas foram sensibilidade, especificidade, área sob a curva (AUC) e matriz de confusão. O modelo apresentado pela rede neural, atingiu melhor previsão para AUC (0.917), sensibilidade (0.861) e especificidade (0.825). A aplicação do modelo de aprendizado de máquina foi assertiva, ao prever 155 dos 180 casos apresentados, onde 25 casos foram classificados entre falso positivo ou falso negativo.

**Palavras-chave:** Modelos de predição; Algoritmos; Inteligência artificial.

#### INTRODUÇÃO

Os modelos de decisão, criados a partir de algoritmos de aprendizado de máquina, são capazes de analisar uma grande quantidade de dados, aprender sobre os dados e extrair *insights* para fornecer subsídios a tomada de decisão, em relação a determinada condição [1]. Mostram-se úteis, diante de um cenário de uma crise sanitária mundial, provocada por um vírus, o que exige a mobilização rápida de recursos materiais e humanos, sobretudo a rápida tomada de decisões. Além disso, são passíveis de aprimoramento e possibilitam o retreinamento [2].

Os algoritmos de aprendizado de máquina, podem ser empregados para identificação de padrões de relacionamento entre sinais e sintomas de determinada doença e, associa ao histórico clínico do paciente, visando a classificação do melhor tratamento, dentre outras aplicações. Durante a pandemia, por exemplo, as aplicações de inteligência artificial foram empregadas para diagnóstico médico por imagens, como exames de raio-X; em aplicativos de smartphones para monitoramento e avaliação de risco da COVID-19 [3].

O presente estudo, objetivou aplicar e comparar algoritmos de aprendizado de máquina para predição da admissão de pacientes internados e contaminados pela COVID-19 em Unidade de Terapia Intensiva.

#### MATERIAIS E MÉTODOS

##### Tipo de estudo

ISBN: 978-65-996901-0-5

Realizou-se um estudo retrospectivo das notificações de pacientes infectados pela COVID-19 no município de Florianópolis.

##### Coleta de dados

Os dados foram coletados no site "covidômetro", no mês de abril de 2021 e abrangeu as notificações de COVID-19 de oito de março de 2020 a 20 de abril de 2021 [4].

##### População e amostra

A população da pesquisa foi composta por 174.704 pacientes notificados com COVID-19. Os critérios de inclusão foram: pacientes com teste positivo para síndrome respiratória aguda grave notificados no município de Florianópolis, internados em complexo hospitalar. Os critérios de exclusão foram pacientes com resultado de teste não informado ou descartado, pacientes com resposta "sim" para cura e óbito na mesma ficha de notificação. Após aplicados os critérios de inclusão e exclusão do estudo restaram 90 pacientes que haviam sido internados em Unidade de Terapia Intensiva (UTI) e foram selecionados randomicamente mais 90 pacientes que passaram por internação hospitalar para manter o equilíbrio dos dados para modelagem. Desta forma, a amostra do estudo foi composta por 180 pacientes.

##### Construção do modelo de aprendizado de máquina

Foram percorridas quatro etapas para a construção do modelo, a saber: pré-processamento de dados, engenharia de atributos, construção do modelo e avaliação do modelo.

164

## ANEXO C – PRINT DO E-MAIL DE ACEITE DA REVISTA BRASILEIRA DE ENFERMAGEM DO ARTIGO 4

Revista Brasileira de Enfermagem - Decision on Manuscript ID REBEn-2022-0740.R3 > Caixa de entrada x



Antonio José Almeida Filho <onbehalf@manuscriptcentral.com>  
para mim, alacoque.erdmann, lincolnsobral

dom., 23 de jul., 11:49 ☆ ↶ ⋮

inglês > português Traduzir mensagem

Desativar para: inglês x

23-Jul-2023

Dear Srta. . Capellari Fabrizioo, Greici Capellari; Erdmann, Alacoque Lorenzini Lorenzini; de Oliveira, Lincoln Moura :

It is a pleasure to accept your manuscript entitled "Web App para predição da internação em Unidade de Terapia Intensiva por COVID-19" in its current form for publication in the Revista Brasileira de Enfermagem. The comments of the reviewer(s) who reviewed your manuscript are included at the foot of this letter.

Thank you for your fine contribution. On behalf of the Editors of the Revista Brasileira de Enfermagem, we look forward to your continued contributions to the Journal.

Sincerely,

Dr(a). Antonio José Almeida Filho  
Editor-in-Chief, Revista Brasileira de Enfermagem  
[editorcientifico.reben@abennacional.org.br](mailto:editorcientifico.reben@abennacional.org.br)

Editor Associado  
Comentários para o autor:  
Prezado autor

## ANEXO D – CERTIFICADO DE REGISTRO DE PROGRAMA DE COMPUTADOR DO *WEB ABB* DESCRITO NO ARTIGO 4



REPÚBLICA FEDERATIVA DO BRASIL  
MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA, COMÉRCIO E SERVIÇOS  
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL  
DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS

### Certificado de Registro de Programa de Computador

Processo Nº: **BR512023002623-9**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 31/03/2022, em conformidade com o 52º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: COVID-19 UTI PREDICTOR

Data de publicação: 31/03/2022

Data de criação: 01/11/2021

Titular(es): UNIVERSIDADE FEDERAL DE SANTA CATARINA

Autor(es): ALACOQUE LORENZINI ERMANN; GREICI CAPELLARI FABRIZIO; LINCOLN MOURA DE OLIVEIRA

Linguagem: PYTHON

Campo de aplicação: SD-01; SD-02; SD-07

Tipo de programa: AP-01

Algoritmo hash: SHA-512

Resumo digital hash:  
824784355c32421a5b8e232488b3bed4dd47fbaed7719a824b1bb299b8f1324ab37ab2c18e9740156c065a19105a45216  
ad182a6fd524a468ba92707d283d4aa

Expedido em: 12/09/2023

Aprovado por:  
Carlos Alexandre Fernandes Silva  
Chefe da DIPTO

## ANEXO E – EDITORIAL SOBRE ENFERMAGEM DE PRECISÃO PUBLICADO PELAS AUTORAS

EDITORIAL

# Enfermería de precisión: una aliada para potenciar la gestión del cuidado

Enfermagem de precisão: uma aliada para potencializar a gestão do cuidado

Precision nursing: An ally to enhance care management

**1 Greici Capellari Fabrizzio**

Departamento de Enfermería, Universidade Federal de Santa Catarina  
(Florianópolis, Santa Catarina, Brasil).  
orcid: <https://orcid.org/0000-0002-3848-5694>  
Correo electrónico: greicicapellari@hotmail.com

**2 José Luís Guedes dos Santos**

Departamento de Enfermería, Universidade Federal de Santa Catarina  
(Florianópolis, Santa Catarina, Brasil).  
orcid: <https://orcid.org/0000-0003-3186-8286>  
Correo electrónico: jose.santos@ufsc.br

**3 Alacoque Lorenzini Erdmann**

Departamento de Enfermería, Universidade Federal de Santa Catarina  
(Florianópolis, Santa Catarina, Brasil).  
orcid: <https://orcid.org/0000-0003-4845-8515>  
Correo electrónico: alacoque.erdmann@ufsc.br

**Cómo citar:** Fabrizzio GC; Santos JL; Erdmann AL. Enfermería de precisión: una aliada para potenciar la gestión del cuidado. *Av Enferm.* 2022;40(2):179-182.  
<http://doi.org/10.15446/av.enferm.v40n2.102949>

DOI: <http://doi.org/10.15446/avenferm.v40n2.102949>

## ANEXO F – ARTIGO SOBRE INTELIGÊNCIA ARTIFICIAL PUBLICADO PELAS AUTORAS

Relato de  
Experiência



### ASSISTENTE VIRTUAL: FERRAMENTA PARA COPRODUÇÃO EM SAÚDE NO ENFRENTAMENTO À COVID-19

Greici Capellari Fabrizzio<sup>1</sup>   
Lincoln Moura de Oliveira<sup>2</sup>   
Diovane Ghignatti da Costa<sup>1</sup>   
Alacoque Lorenzini Erdmann<sup>1</sup>   
José Luís Guedes dos Santos<sup>1</sup>

<sup>1</sup>Universidade Federal de Santa Catarina, Programa de Pós-graduação em Enfermagem, Florianópolis, Santa Catarina, Brasil.

<sup>2</sup>Universidade Federal do Ceará, Programa de Pós-graduação em Engenharia Elétrica, Fortaleza, Ceará, Brasil.

#### RESUMO

**Objetivo:** descrever o desenvolvimento de um assistente virtual como ferramenta potencial para a coprodução em saúde no enfrentamento à COVID-19.

**Método:** trata-se de uma pesquisa aplicada de produção tecnológica, desenvolvida nos meses de março e abril de 2020 em cinco etapas: 1) revisão de literatura, 2) definição de conteúdo, 3) construção do diálogo, 4) teste do protótipo e 5) integração com página de mídia social.

**Resultados:** a revisão de literatura reuniu evidências científicas sobre a doença a partir das publicações do Ministério da Saúde, no Brasil, e de consultas em artigos científicos. O conteúdo foi construído a partir das perguntas mais realizadas pela população, em março de 2020, evidenciadas por meio do *Google Trends*, em que emergiram os seguintes temas: conceito da doença, formas de prevenção, transmissão da doença, principais sintomas, formas de tratamento e dúvidas. A construção do diálogo foi baseada em Processamento de Linguagem Natural, intenções, entidades e estrutura de diálogo. O protótipo foi testado em laboratório com um número reduzido de computadores usuários em uma rede local para verificar a funcionalidade do conjunto de aplicações, erros técnicos e visuais acerca do diálogo e se as respostas fornecidas estavam de acordo com a pergunta do usuário, respondendo de forma correta os questionamentos e integrado ao Facebook.

**Conclusão:** o assistente virtual mostrou-se uma ferramenta de educação em saúde e com potencial para combater *fake news*. Também representa uma forma de comunicação em saúde centrada no paciente, que favorece o fortalecimento de vínculo e interação entre profissionais de saúde e pacientes, promovendo a coprodução em saúde.

**DESCRITORES:** COVID-19. Pandemias. Informática médica. Aplicações de informática médica. Tecnologia da informação. Processamento de linguagem natural. Inteligência artificial.

**COMO CITAR:** Fabrizzio GC, Oliveira LM, Costa DG, Erdmann AL, Santos SLG. Assistente virtual: ferramenta para coprodução em saúde no enfrentamento à COVID-19. *Texto Contexto Enferm* [Internet]. 2023 [acesso MÊS ANO DIA]; 32:e20220136. Disponível em: <https://doi.org/10.1590/1980-265X-TCE-2022-0136pt>

